



Sveučilište u Zagrebu

FILOZOFSKI FAKULTET

Mia Šetić

ULOGA PERCEPCIJE U POJMOVNOM PROCESIRANJU

DOKTORSKI RAD

Mentor: Prof. dr. sc. Dražen Domijan

Zagreb, 2016.



University of Zagreb

FACULTY OF HUMANITIES AND SOCIAL SCIENCES

Mia Šetić

THE ROLE OF PERCEPTION IN CONCEPTUAL PROCESSING

DOCTORAL THESIS

Supervisor: Prof. dr. sc. Dražen Domijan

Zagreb, 2016.

O MENTORU

Prof. dr. sc. Dražen Domijan rođen je u Rijeci, 13. kolovoza 1973. godine. Diplomirao je psihologiju 1996. na Filozofskom fakultetu u Rijeci, a doktorirao 2000. godine na Filozofskom fakultetu u Zagrebu.

1996. godine dobio je Rektorovu nagradu Sveučilišta u Rijeci, a 1997. godine psihologijsku nagradu Zlatna značka Ramira Bujasa za osobito vrijedan diplomski rad. Od 1997. radi na Odsjeku za psihologiju Filozofskog fakulteta u Rijeci gdje je 2014. godine izabran u znanstveno-nastavno zvanje redovitog profesora.

Do sada je objavio više od 30 znanstvenih i preglednih radova iz područja percepcije, pažnje, radnog pamćenja i jezičnog razumijevanja. S priopćenjima je sudjelovao na više od 50 domaćih i međunarodnih znanstvenih skupova. Bio je voditelj nekoliko domaćih i jednog međunarodnog znanstvenog projekta. Na primjer, vodio je projekt Uspostavne potpore *Modeliranje kognitivnih i neuronskih sustava* kojeg je financirala Hrvatska zaklada za znanost i međunarodni projekt *Understanding the role of dendrites in cortical information processing* iz područja neurofiziologije kojeg je financirala zaklada Bial iz Portugala.

Bio je predstojnik Katedre za Metodologiju i opću psihologiju te voditelj Laboratorija za eksperimentalnu psihologiju. Član je uredničkog odbora časopisa *Review of Psychology*.

Ovaj rad posvećujem svojim roditeljima

Vesni i Miljenku

SAŽETAK

Jedan od središnjih problema kognitivne znanosti je pitanje kako je pojmovno znanje reprezentirano u ljudskom umu. Teorija perceptivnih simboličkih sustava pretpostavlja da je znanje ukorijenjeno u modalno-specifičnim sustavima kao što su percepcija, motorika i emocije. Prema ovoj teoriji, perceptivna iskustva spremaju se u memorijske sustave koji se po potrebi mogu reaktivirati i oživjeti tijekom konceptualne obrade pomoću perceptivne simulacije. Važna kritika teorije je da ona može objasniti utjecaj perceptivnih varijabli na razumijevanje konkretnih pojmova, jer se objekti na koje se oni referiraju mogu lako predočiti, ali ne može objasniti kako razumijemo značenje apstraktnih pojmova te se postavlja pitanje imaju li perceptivne varijable utjecaj i na njihovu obradu.

Cilj ovog istraživanja bio je ispitati je li razumijevanje značenja numeričkih pojmova utemeljeno u percepciji. Preciznije, u prvih šest eksperimenata cilj je bio ispitati jesu li elementarne aritmetičke operacije utemeljene u kretanju duž zajedničke prostorne reprezentacije veličina koja obuhvaća sve kvantitativne dimenzije kao što su prostor, vrijeme, brojevi i svjetlina. Osim toga, u sedmom i osmom eksperimentu ispitano je mogu li se mali brojevi utemeljiti u sustavu za subitizaciju odnosno sustavu za brzo i automatsko prebrojavanje malih skupova objekata u vidnom polju. U prvih šest eksperimenata ispitanici su rješavali aritmetičke zadatke koji su bili prikazani u crnoj ili bijeloj boji, a u sedmom i osmom eksperimentu ispitanici su uspoređivali rečenice i slike koje su varirale s obzirom na broj objekata spomenutih u rečenici i prikazanih na slici. U svim provedenim eksperimentima mjerena je i analizirana brzina i točnost rješavanja zadataka.

Rezultati prvih šest eksperimenata pokazali su postojanje interakcije između aritmetičkih operacija zbrajanja i oduzimanja i boje kojom su prikazani. Međutim, ovaj efekt ne može se pripisati utemeljenju odnosno preslikavanju na zajedničku reprezentaciju veličine budući da efekt nestaje kada se zadaci zbrajanja i oduzimanja prikazuju odvojeno. Umjesto toga, dobivena interakcija između aritmetičkih operacija i boje može se pripisati metaforičkom preslikavanju između kategorijalnih suprotnosti (bijelo-crno i zbrajanje-oduzimanje). S druge strane, rezultati sedmog i osmog eksperimenta pokazali su postojanje interferencije kada se ne podudaraju broj spomenut u rečenici i brojnost objekata prikazanih na slici u zadatku usporedbe riječi i slike, što ukazuje na mogućnost da je značenje malih brojeva utemeljeno u sustavu za brzo prebrojavanje malih skupova.

Rezultati istraživanja pokazuju kako značenje numeričkih pojmova može biti utemeljeno u sustavu za subitizaciju, ali ne i u zajedničkom sustavu za reprezentaciju veličina, što djelomično ide u prilog teoriji perceptivnih simboličkih sustava.

Ključne riječi: aritmetika, brojevi, percepcija, perceptivna simulacija, pojmovno znanje

SUMMARY

Introduction

One of the central issues in cognitive science is to understand how conceptual knowledge is represented in the mind. According to the theory of perceptual symbol systems, knowledge is grounded in modality-specific systems for perception, action and emotion. Perceptual experiences are stored in memory and they can be reactivated during conceptual processing via perceptual simulation. Important criticism of the theory is that it can explain understanding of concrete concepts because it is easy to visualize their referent objects but it is not clear how abstract concepts are processed and whether perceptual variables affect their understanding also. Aim of this research was to examine whether numerical concepts are grounded in perception.

Methodology

In experiments 1 - 6, I examined whether elementary arithmetic operations are grounded in the motion along the general spatial representation of magnitude which encompasses all quantitative dimensions such as space, time, numbers and brightness. Furthermore, in experiments 7 - 8, I examined whether small numbers are grounded in the system for subitization, that is, for automatic enumeration of small sets of objects in the visual field. In the experiments 1 - 6, participants solved arithmetic problems that appeared either in black or white font. In the experiments 7 - 8, participants compared sentences and pictures that varied in number mentioned in sentence and in numerosity of objects depicted in picture. Speed and accuracy of performance was recorded and analyzed.

Results and discussion

Results of experiments 1 - 6 showed that there is interaction between arithmetic operations of addition and subtraction and colours in which they are presented. However, this effect cannot be attributed to the grounding or mapping onto general magnitude representation because the effect disappears when the addition and subtraction problems are presented separately. Instead, the results are consistent with the metaphorical mapping between conceptual polarities (white-black and addition-subtraction). On the other hand, results of

experiments 7 - 8 showed that there is interference when there is no match between number mentioned in the sentence and numerosity of objects presented in the subsequent picture which implies that small numbers are grounded in system for subitization.

Conclusion

The results of the current research showed that numerical concepts are grounded in system for subitization or rapid enumeration of small sets but not in the common system for representation of magnitude. Such outcome provides partial support for the theory of perceptual symbol systems.

Keywords: Arithmetic, Numbers, Perception, Perceptual Simulation, Conceptual Knowledge

SADRŽAJ

1. UVOD	1
1.1. UTJELOVLJENA SPOZNAJA.....	1
1.1.1. Reprezentacija znanja.....	2
1.1.2. Teorija o perceptivnim simboličkim sustavima.....	5
1.1.3. Pojmovi i perceptivna simulacija.....	7
1.1.4. Pojmovi i prostor	9
1.1.5. Razumijevanje jezika.....	13
1.1.5.1. Prožeti iskustvenik	13
1.1.5.2. Indeksna hipoteza	15
1.1.5.3. Jezik i perceptivna simulacija.....	16
1.1.6. Utjelovljenje u socijalnoj psihologiji.....	20
1.1.7. Edukacija i utjelovljenje.....	23
1.1.8. Neuronske osnove utjelovljenja	24
1.1.9. Simulacija, zrcalni sustav i razumijevanje drugih ljudi.....	28
1.1.10. Kritike utjelovljenja	31
1.1.11. Apstraktni pojmovi.....	32
1.1.12. Gramatika	35
1.1.13. Kontinuum utjelovljenja.....	36
1.1.14. Zaključno o utjelovljenju.....	40
1.2. NUMERIČKA SPOZNAJA	42
1.2.1. Sustav za egzaktno brojeve.....	43
1.2.1.1. Usporedba brojeva po veličini.....	44
1.2.1.2. SNARC efekt i mentalna numerička linija.....	45
1.2.1.3. Analogni integrator	46
1.2.1.4. Brojevi i prostor	47
1.2.1.5. Mentalna aritmetika.....	51
1.2.2. Sustav za percepciju brojnosti (Osjet za brojeve).....	56
1.2.2.1. Metodološki aspekti istraživanja procjene brojnosti kod životinja i predverbalne djece.....	56
1.2.2.2. Procjena brojnosti kod životinja.....	57
1.2.2.3. Procjena brojnosti kod predverbalne djece	59
1.2.2.4. Neuronske osnove osjeta za brojeve	61

1.2.2.5. Neuropsihologija	62
1.2.2.6. Neurofiziološka istraživanja.....	63
1.2.2.7. Opća reprezentacija veličina	65
1.2.3. Sustav za automatsko prebrojavanje	67
1.2.4. Interakcije među sustavima.....	71
1.2.4.1. Razvoj pojma egzaktnog broja kod djece	73
1.2.4.2. Kulturalne razlike u razumijevanju egzaktnih brojeva.....	76
1.2.5. Modeli numeričke spoznaje.....	78
1.2.5.1. McCloskey-ev apstraktni modularni model	78
1.2.5.2. Dehaene-ov model trostrukog koda	79
1.2.5.3. Campbellova hipoteza o kompleksu kodiranja	80
1.2.6. Zaključno o numeričkoj spoznaji	81
2. PROBLEM ISTRAŽIVANJA.....	82
3. HIPOTEZE.....	84
4. METODA.....	86
4.1. EKSPERIMENT 1	86
4.2. EKSPERIMENT 2	89
4.3. EKSPERIMENT 3	91
4.4. EKSPERIMENT 4	92
4.5. EKSPERIMENT 5	93
4.6. EKSPERIMENT 6	94
4.7. EKSPERIMENT 7	95
4.8. EKSPERIMENT 8	98
5. REZULTATI	100
5.1. EKSPERIMENT 1	100
5.2. EKSPERIMENT 2	103
5.3. EKSPERIMENT 3	106
5.4. EKSPERIMENT 4	109
5.5. EKSPERIMENT 5	112
5.6. EKSPERIMENT 6	115
5.7. EKSPERIMENT 7	118
5.7.1. Analiza po ispitanicima.....	118

5.7.2. <i>Analiza po riječima</i>	120
5.8. EKSPERIMENT 8	121
5.8.1. <i>Analiza po ispitanicima</i>	121
5.8.2. <i>Analiza po riječima</i>	123
6. DISKUSIJA	124
6.1. EKSPERIMENTI 1 - 6	124
6.2. EKSPERIMENTI 7 I 8	132
6.3. NEURODINAMIČKI MODEL UTEMELJENJA SIMBOLA	134
7. ZAKLJUČAK	139
8. LITERATURA	141
9. PRILOZI	167
9.1. EKSPERIMENT 1	167
9.2. EKSPERIMENT 4	168
9.3. EKSPERIMENT 5	169
9.4. EKSPERIMENT 6	170
9.5. EKSPERIMENT 7	171
9.6. EKSPERIMENT 8	174
10. ŽIVOTOPIS	177
11. POPIS OBJAVLJENIH RADOVA	178

1. UVOD

1.1. Utjelovljena spoznaja

Prema standardnom modelu kognitivne znanosti, ljudski um je složeni sustav za obradu informacija (računalo) čije veze s vanjskim svijetom nemaju neko bitno teorijsko značenje. Ključ za razumijevanje ljudske inteligencije leži u poistovjećivanju mišljenja s procesom računanja odnosno manipuliranja simboličkim reprezentacijama korištenjem ako-onda (*if-then*) pravila ili produkcija. Mišljenje se promatra kroz analogiju s jezikom. Kao što jezik ima svoje simbole (riječi) i pravila (sintaksu) koja određuju kako se riječi smiju kombinirati u nove rečenice, tako i mišljenje ima svoje simbole i pravila koja omogućuju generiranje novih misli (Fodor, 1975). Pri tome, bitno svojstvo simbola je da su arbitrarni s obzirom na objekte koje označavaju, odnosno simbol ni na koji način ne odražava perceptivna svojstva referentnog objekta.

U okviru standardnog modela, perceptivni i motorni sustav, iako sami po sebi zanimljivi za proučavanje, ne smatraju se relevantnim za razumijevanje centralnih kognitivnih funkcija kao što su jezik, mišljenje ili rješavanje problema. Umjesto toga, oni samo predstavljaju ulazno-izlazne uređaje. Prema teoriji o modularnosti uma, svaka kognitivna funkcija je zaseban modul izoliran od ostalih. Moduli međusobno ne komuniciraju, već komuniciraju samo s centralnim izvršiteljem odnosno procesorom (Fodor, 1983). Takav stav dominirao je u počecima kognitivne psihologije kada je većina teorija o mišljenju i jeziku bila predstavljana u obliku propozicija, odnosno apstraktnih pravila za manipulaciju simbolima. Primjeri takvih teorija su Collins i Quillianov (1969) model širenja aktivacije ili Kintchova (1988) teorija konstrukcije-integracije. U isto vrijeme, u području umjetne inteligencije dominirali su modeli generalnih kognitivnih arhitektura zasnovani na produkcijskim sustavima kao što su SOAR (Laird, Rosenbloom i Newell, 1987) i ACT (Anderson, 1990).

Međutim, u zadnjih dvadesetak godina razvio se radikalno drugačiji pristup u kognitivnoj znanosti koji postavlja tijelo u fokus istraživačke pažnje, a ne um koji radi na apstraktnim problemima. Prema tom pristupu, tijelo ima centralnu ulogu u oblikovanju uma, jer tijelo kroz akciju stalno stupa u interakciju s okolinom i treba um kako bi moglo funkcionirati (Glenberg, 2010; Glenberg, Witt i Metcalfe, 2013). Ovakav pristup koji naglašava važnost osjetnih i motornih funkcija za uspješnu interakciju s okolinom nazvan je

utjelovljena spoznaja (*embodied cognition*) ili utemeljena spoznaja (*grounded cognition*). Utjelovljena spoznaja nije u potpunosti novost jer je i u povijesti psihologije bilo primjera autora koji su naglašavali važnost tijela za um. Na primjer, William James je predložio motornu teoriju percepcije, razvojni psiholog Jean Piaget je naglašavao važnost osjetno-motornih sposobnosti kao temelja za razvoj kognitivnih sposobnosti, a Gibson (1979) je razvio ekološku teoriju percepcije u kojoj važnu ulogu imaju afordanse (*affordances*) koje čine osnovu za potencijalnu interakciju s okolinom. U umjetnoj je inteligenciji također došlo do pomaka interesa od konstrukcije internalnih reprezentacija na programiranje rutina za interakciju s okolinom. Takav pristup nazvan je ponašajno-zasnovana robotika (*behavioral-based robotics*). Dakle, u različitim područjima kognitivne znanosti sazrijela je svijest o važnosti proučavanja uma u kontekstu odnosa s fizičkim tijelom i njegovom interakcijom sa svijetom (Wilson, 2002). Takva orijentacija je rezultirala nizom istraživanja koja pokazuju da osjetne i motorne varijable doista imaju ulogu u višim kognitivnim procesima. Detaljan prikaz ovih istraživanja dali su Gibbs (2006) i Pecher i Zwaan (2005). Iako ne postoji cjelovita teorija o utjelovljenoj spoznaji koja bi obuhvatila sve kognitivne domene, u području reprezentacije znanja Barsalou (1999; 2003) je razvio teoriju o perceptivnim simboličkim sustavima koja će biti detaljnije opisana u sljedećem poglavlju.

1.1.1. Reprezentacija znanja

Jedno od centralnih problema kognitivne znanosti je pitanje kako je znanje reprezentirano u ljudskom umu. Markman i Dietrich (2000) definiraju reprezentaciju kao posredujuće stanje inteligentnog sustava koje nosi informaciju. Glavno obilježje reprezentacije jest da je to trajno stanje koje sadrži određene simbole i koje nije vezano uz percepciju i motoriku. Iz toga proizlazi da je moguće modelirati (objasniti) većinu kognitivnih funkcija bez obzira na perceptivne i motorne procese inteligentnog sustava. Drugim riječima, klasični pogled na reprezentaciju znanja pretpostavlja da je znanje pohranjeno u posebnom semantičkom sustavu koji je odvojen od ostalih modalno-specifičnih sustava za percepciju, akciju i emocije. Dakle, znanje je amodalno tj. neovisno od modaliteta iz kojeg je ekstrahirano i nad njim se operira pomoću drugačijih pravila nego u modalnim sustavima. Na primjer, pretpostavimo da percipiramo objekt kao što je automobil. Prema teoriji o amodalnoj reprezentaciji najprije se u vidnom sustavu stvara modalna reprezentacija

automobila koja se zatim pretvara u druge reprezentacijske formate kao što su lista obilježja, semantička mreža ili okvir koji su neovisni o percepciji. Ovaj proces pretvaranja jednog reprezentacijskog formata (perceptivnog) u drugi (semantički) naziva se transdukcija. Kada je transdukcija gotova, inteligentni sustav može samostalno operirati nad semantičkom reprezentacijom kako bi riješio određeni zadatak bez oslanjanja ili pozivanja na perceptivnu reprezentaciju.

Lista obilježja sadrži svojstva percipiranog objekta kao što su fizički objekt, motor, kotači, ali ne i amodalnu sliku objekta, tj. njegovu boju, oblik. Semantička mreža je niz pojmova koji su povezani relacijskim čvorovima koji opisuju odnose među pojmovima. Relacijski čvorovi su "*ima*", "*je*", "*na*" koji opisuju odnose kao: automobil ima motor ili automobil ima četiri kotača ili automobil je vozilo. Doziv znanja iz semantičke mreže odvija se putem kretanja od jednog čvora do drugog, dok ne dođemo do čvora koji sadrži traženu informaciju. Okvir je statična struktura podataka koja opisuje situaciju ili objekt slično kao u bazama podataka. Na primjer, objekt kao što je automobil može se opisati sljedećom strukturom: motor = da, kotači = 4, upotreba = prijevoz. Iz toga proizlazi da svakom perceptivnom iskustvu pridjeljujemo određene amodalne simbole u apstraktnom reprezentacijskom formatu koji više ne ovisi o detaljima tog iskustva. Takvi apstraktni ili amodalni opisi percipiranog objekta mogu poslužiti kao znanje za kognitivne procese kao što su pamćenje, jezik i mišljenje (Barsalou, Simmons, Barbey i Wilson, 2003).

Važan problem za semantičke mreže, liste obilježja i okvire je da ne preciziraju kako je značenje pojmova usvojeno odnosno kako se gradi unutar danog reprezentacijskog formata. U takvim modelima, značenje je dostavljeno izvana odnosno pruža ga programer koji *ubacuje* relevantne definicije pojmova u sustav prije nego što se pristupi testiranju svojstava takvog sustava. Kako bi se riješio ovaj problem u okviru amodalnog pristupa, predloženi su modeli koji ekstrahiraju značenje riječi iz statističkih pravilnosti njihovog zajedničkog pojavljivanja u tekstu. Prema hiperprostornoj analogiji jezika (*Hyperspace analogue to language - HAL*) koju su predložili Burgess i Lund (1997), značenje riječi nastaje iz dimenzionalne analize različitih konteksta u kojima se riječ pojavljuje. U ovom modelu polazi se od velikog korpusa riječi i tekstova koji se analiziraju koristeći pomični prozor veličine 10 riječi. Kreira se velika dvodimenzionalna matrica sa otprilike 70.000 stupaca i redaka. Svaki redak i stupac je označen s jednom riječju. Na taj način, svaka lokacija u matrici sadrži kvantitativnu mjeru blizine dviju riječi unutar pokretnog prozora. Na primjer, ako se dvije riječi pojavljuju odmah jedna uz drugu dobivaju vrijednost 10. Ako su razmaknute za jednu riječ, dobivaju vrijednost

9, ako su razmaknute za dvije riječi dobivaju vrijednost 8 i tako dalje. Kada se spoje stupac i redak za istu riječ, dobivamo vektor veličine 140.000 elemenata koji predstavlja značenje riječi. Burgess i Lund (1997) su pokazali da ovakva vektorska reprezentacija značenja korelira s rezultatima ispitanika na zadacima koji ispituju značenje. Na primjer, sličnost između dvije riječi izražena kao udaljenost između njihovih vektora dobro predviđa snagu semantičke pripreme (priminga) u zadatku leksičke odluke.

Prema latentnoj semantičkoj analizi (*latent semantic analysis* - LSA) koju su predložili Landauer i Dumais (1997) značenje proizlazi iz statističke analize zajedničkog pojavljivanja riječi. Kao i kod HALa i kod LSA se kreće od matrične reprezentacije riječi s tom razlikom da kod LSA svaki redak predstavlja jednu riječ, a svaki stupac predstavlja jedan tekst iz korpusa. Na primjer, ako se kao korpus tekstova uzme neka enciklopedija (Landauer i Dumais su uzeli Grolier američku akademsku enciklopediju s 30.473 natuknice), tada je svaka natuknica u enciklopediji zaseban kontekst odnosno stupac u matrici. Svaki element matrice označava broj koliko puta se neka riječ spomene u danom tekstu. Nad tako pripremljenom matricom se primijeni singularna dekompozicija vrijednosti (*singular value decomposition* - SVD). To je matematički postupak sličan ekstrakciji eigen vrijednosti u faktorskoj analizi. Kao rezultat primjene SVD-a dobiva se latentni semantički prostor od 300 do 400 dimenzija pri čemu je značenje riječi određeno kao položaj točke u tom prostoru. Landauer i Dumais (1997) su proveli niz testova kojima su pokazali da LSA može modelirati različite aspekte usvajanja znanja. Na primjer, LSA postiže razinu izvedbe na testu sinonima engleskog jezika (*TOEFL - Test of English as a Foreign Language*) sličan studentima kojima engleski nije materinji jezik. Brzina usvajanja značenja novih riječi, s obzirom na količinu apsorbiranog teksta, usporediva je s brzinom usvajanja riječi kod djece. Nadalje, prosječne vrijednosti vektora za rečenice povezane su sa subjektivnim procjenama koherentnosti rečenica.

HAL i LSA su motivirali razvoj novih računalnih metoda ekstrahiranja znanja iz velikih korpusa tekstova koji pokazuju impresivne mogućnosti simulacije semantičkog pamćenja (McNamara, 2011). Međutim, ključni nedostatak svih statističkih modela je da su u svojoj suštini amodalni i ne mogu riješiti problem uzemljenja ili utemeljenja simbola (*symbol grounding*) na koji su prvi upozorili Searle (1980) i Harnad (1990). Problem se sastoji u tome da simbolička reprezentacija znanja ne daje odgovor na pitanje kako su simboli povezani s vanjskim svijetom odnosno s objektima koje označavaju. Problem se može prikazati misaonim eksperimentom u kojem čovjek dolazi na aerodrom u nekoj stranoj zemlji čiji jezik ne razumije (npr. kineski). Kako bi se snašao i protumačio simbole na natpisima, čovjek

kupuje rječnik, ali u tom rječniku svi su simboli objašnjeni s drugim simbolima iz istog jezika. Dakle, da bi shvatio značenje simbola na natpisima, čovjek mora odgonetnuti značenje prvog simbola u rječniku koji objašnjava traženi simbol. Međutim, kako čovjek ne razumije ni taj prvi simbol mora u rječniku potražiti njegovo značenje, ali i on je također definiran nekim drugim nerazumljivim simbolima i tako se čovjek vrti u krug i nikako ne uspijeva dokučiti značenje simbola na natpisima. Drugim riječima, reprezentacija znanja koja se sastoji samo od relacija među simbolima ne može u potpunosti zahvatiti značenje pojmova jer joj nedostaje kontakt s referentnim objektima, odnosno nedostaje joj utemeljenje u okolini.

Drugi, jednako važan, problem za amodalnu reprezentaciju jest činjenica da nikada nije precizirano kako se odvija transdukcija od perceptivnih prema amodalnim simboličkim reprezentacijama. To nije jednostavno riješiti jer su perceptivne i simboličke reprezentacije kvalitativno različite. Simboli su jasno odvojeni, fiksni, diskretni paketići informacija, dok je percepcija kontinuirana i dinamična. Na primjer, riječ CRVENO je simbol koji označava određeno perceptivno iskustvo viđenja površine objekta. Međutim, postoji veliki broj različitih nijansi crvene boje koje jasno percipiramo kao različite, iako nemamo zasebne simbole za sve te varijacije nego ih sve označavamo kao CRVENO. Drugim riječima, svaki simbol moguće je preslikati na ogroman broj različitih perceptivnih situacija. U okviru standardnog modela nikada nije specificiran algoritam odnosno postupak kako razgraničiti (diskretizirati) perceptivna iskustva da bi ih se moglo povezati sa simbolima. U umjetnoj inteligenciji taj problem rješava programer tako da isprogramira sve moguće propozicije vezane za neki pojam. Nadalje, do sada nisu pronađeni neuronski mehanizmi koji bi podržali transdukciju.

1.1.2. Teorija o perceptivnim simboličkim sustavima

Nasuprot tradicionalnom pristupu, Barsalou (1999) postavlja radikalno drugačiju teoriju o reprezentaciji znanja u kojoj pojmove ne možemo odvojiti od konkretnog iskustva s njihovim referentnim objektima. Teorija polazi od pretpostavke da je znanje ukorijenjeno (utemeljeno) u sustavima za specifične modalitete kao što su percepcija, motorika i emocije. Iz toga proizlazi kako nije potrebna transdukcija u zasebnu amodalnu simboličku reprezentaciju. Drugim riječima, teorija rješava i problem utemeljenja simbola i problem transdukcije. Umjesto transdukcije, perceptivna iskustva se spremaju direktno u perceptivne

memorijske sustave, a motorna iskustva se spremaju u motorne memorijske sustave koji se po potrebi mogu reaktivirati i oživjeti. Reaktiviranje perceptivnih iskustava naziva se perceptivnom simulacijom ili indirektnim utjelovljenjem (*off-line embodiment*). Reaktivacija motornih iskustava naziva se direktno utjelovljenje (*on-line embodiment*) zato jer se pritom aktiviraju reprezentacije vlastitog tijela. Svaki put kada razmišljamo o nekom pojmu djelomično se aktiviraju perceptivna iskustva objekta kojeg taj pojam označava. Ova iskustva nisu savršena i detaljna, ali su dovoljna da nam omoguće razumijevanje pojma. Dakle, simulacija nije isto što i percepcija jer uključuje određeni stupanj apstrahiranja, odnosno shematizacije kojom se isključuju nebitni detalji i zadržavaju samo ključna obilježja označenog objekta. Konstrukt perceptivne simulacije može se promatrati kao vrsta mentalne imaginacije. Međutim, dok je imaginacija svjesni proces koji zahtijeva mentalni napor, simulacije se uglavnom odvijaju na nesvjesnoj razini (Barsalou, 1999). Simulacije se mogu razviti za bilo koju vrstu iskustva, dakle za percipirane objekte, motorne radnje, događaje, mentalna stanja, emocije itd. Vrlo često je simulacija multimodalna, što znači da se aktivira više sustava istovremeno.

Barsalou (1999) uvodi još dva mehanizma, a to su selektivna pažnja i memorijska integracija kako bi razvio potpuno funkcionalan konceptualni sustav. Uloga selektivne pažnje je da ograničava svim perceptivnim informacijama pristup pamćenju jer ih ima previše. Pažnja odstranjuje nebitne perceptivne detalje i odabire samo one bitne informacije koje će se pohraniti u pamćenje. Na taj način kreira se perceptivni simbol objekta. Međutim, perceptivni simboli nisu izolirani nego se integriraju u memorijsku strukturu koja se naziva okvir. Pri tome, treba napomenuti da se pod pojmom okvir ne misli na amodalnu reprezentaciju kako ju je predložio Minsky (1975), već se radi o strukturi koja se nalazi unutar senzorno-motornog pamćenja. Okvir je integrirani sustav perceptivnih simbola koji omogućuje simulaciju cijele pojmovne kategorije. Na primjer, pretpostavimo da smo se susreli s novom markom automobila koju nikad prije nismo vidjeli. U tom slučaju, shematizirana slika automobila nadodaje se prethodno spremljenim vidnim reprezentacijama automobila koji su već prije viđeni. Tako se stvara reprezentacija kategorije automobili koja uključuje niz različitih vidnih iskustava s različitim tipovima automobila. Nadalje, pažnja se može fokusirati i na dijelove automobila pa se tako mogu kreirati perceptivni simboli za karoserije, kotače, vrata koji također participiraju u okviru. Isto tako, u okvir se integriraju i informacije iz drugih modaliteta te je okvir obogaćen informacijama ne samo o tome kako automobili izgledaju nego i kakve zvukove i mirise proizvode ili kakve osjećaje izazivaju. Kada se želi kreirati

specifična simulacija, pažnja odabire dijelove okvira koji se relevantni za dani pojam. Na primjer, pojam Ferrari izazvat će simulaciju oblika karoserije koji je karakterističan za Ferrari, kao i simulaciju crvene boje budući da je to tipična boja za ovu marku automobila. Međutim, simulacija neke druge marke automobila neće izazvati aktivaciju sustava za boje jer one nemaju jednu tipičnu boju koja se vezuje uz njih. Naravno, moguće je i kreirati simulaciju cijele kategorije automobila koja će uključivati samo općenita perceptivna obilježja koja se javljaju kod svih automobila.

Iako teorija perceptivnih simboličkih sustava nije u potpunosti razvijena jer joj nedostaje specifikacija računalnih mehanizama koji upravljaju perceptivnim simulacijama te njihovim kombiniranjem, ona ipak predstavlja intrigantnu alternativu klasičnim teorijama reprezentacije znanja. Predikcije derivirane iz teorije perceptivnih simboličkih sustava detaljno se istražuju u psihologijskim i neuroznanstvenim studijama u zadnjih petnaestak godina (Barsalou, 2008; Gibbs, 2006; Zwaan, 2008). Primjerice, direktna posljedica perceptivne simulacije je da svojstva senzorno-motornih sustava utječu na razumijevanje pojmova kao što i pojmovna obrada utječe na percepciju i motoriku, a rezultati ovih istraživanja detaljno su opisani u idućim poglavljima.

1.1.3. Pojmovi i perceptivna simulacija

Kako bi se eksperimentalno ispitale pretpostavke teorije perceptivnih simboličnih sustava korišten je zadatak verifikacije svojstva. U ovom zadatku ispitaniku se najprije prezentira riječ za kategoriju (npr. mačka), nakon čega se prezentira svojstvo za koje ispitanik mora odgovoriti je li ono karakteristično za prethodno danu kategoriju (pandže, krila). Pri tome se pretpostavlja da ovaj zadatak aktivira i koristi pojmovno znanje. Ako je pojmovno znanje ukorijenjeno u modalno-specifičnim sustavima tada se pojave vezane za pojedini modalitet trebaju manifestirati i tijekom pojmovnog procesiranja. Solomon i Barsalou (2001) su pokazali da vidni oblik svojstva koje se ispituje ima utjecaj na zadatak verifikacije svojstva. Kada su ispitanici verificirali svojstvo na prethodnom zadatku, korištenje istog svojstva u sljedećem zadatku dovelo je do facilitacije kada je detaljni oblik svojstva bio odgovarajući za oba pojma. Na primjer, do facilitacije je dovelo verificiranje svojstva griva kada je prvo bio prezentiran pojam konj, a zatim pojam magarac. S druge strane, do facilitacije nije došlo kada je isto svojstvo griva korišteno za različite pojmove (konj i lav).

Naime, griva kod konja i lava ima bitno drugačiji oblik zbog čega nije moglo doći do facilitacije. Naravno, ovo objašnjenje ima smisla ako pretpostavimo da je tijekom rješavanja zadatka korištena perceptivna simulacija odnosno stvorena je mentalna slika o izgledu svojstva vezanog uz pojam.

Pored toga, u zadatku verifikacije svojstva javlja se i usporavanje izvedbe (gubitak vremena) kada je potrebno promijeniti modalitet u kojem se verificira svojstvo. Pecher, Zeelenberg i Barsalou (2003) su pokazali da je potrebno kraće vrijeme da se odgovori je li *glasno* svojstvo koncepta MJEŠALICA (za cement) kada je prethodno trebalo verificirati je li *šuštanje* svojstvo pojma LIŠĆE (ista perceptivna dimenzija, sluh), u usporedbi sa situacijom kada je prethodno trebalo verificirati je li *kiselo* svojstvo pojma BOROVNICE (promjena perceptivne dimenzije, okus). Ovaj rezultat pokazao je da razmišljanje o nekom pojmu doziva perceptivne informacije iz pamćenja relevantne za taj pojam. Nadalje, kako promjena fokusa pažnje s jedne perceptivne dimenzije na drugu izaziva gubitak vremena potrebnog za obradu informacija, isti gubitak u obradi informacija javlja se i za semantičku obradu vezanu uz te dimenzije. Zanimljivo je da su Niedenthal i sur. (2007) pokazali da se isti efekt gubitka vremena javlja i kod verifikacije svojstava emocionalnih pojmova.

U prethodno opisanim istraživanjima ne ispituje se direktno percepcija, već se o njenim efektima naknadno zaključuje na osnovu razlika u brzini reagiranja ispitanika. Zbog toga je otkrivene efekte gubitka vremena moguće objasniti i u okviru amodalne teorije uz pretpostavku da su svojstva koja dolaze iz istog modaliteta međusobno jače povezana nego svojstva iz različitih modaliteta. Direktniju potvrdu za ulogu perceptivne simulacije pružilo bi istraživanje u kojem tekuća perceptivna obrada utječe na izvedbu na zadatku pojmovnog znanja. Vermeulen, Corneille i Niedenthal (2008) manipulirali su modalitetom perceptivnog opterećenja u radnom pamćenju ispitanika dok rješava zadatak. Dobili su da je verificiranje vidnih svojstava (žuto, okruglo) usporeno kada je opterećeno vidno radno pamćenje, a verificiranje slušnih svojstava (glasno, tiho) kada je opterećeno slušno radno pamćenje. Isto tako, van Dantzig, Pecher, Zeelenberg i Barsalou (2008) su otkrili da kada ispitanici naizmjenično rješavaju zadatak perceptivne detekcije i verifikacije svojstva dolazi do usporenja verifikacije svojstva ako je prethodni perceptivni zadatak bio u drugom modalitetu nego kada je bio u istom modalitetu kao i svojstvo koje se verificira. Sličan efekt dobiven je i za motorne radnje, pri čemu je korišten zadatak imenovanja objekata. Ispitanici su stiskali gumenu loptu dok su imenovali oruđa ili životinje prikazane na slici. Rezultati su pokazali da su ispitanici bili brži u imenovanju oruđa čija je drška bila okrenuta od ruke koja stiže loptu,

nego oruđa s drškom okrenutom prema ruci. Kod imenovanja životinja nije pronađena takva razlika. Kao i u prethodnom istraživanju, ovaj nalaz se može pripisati interferenciji između izvođenja radnje i perceptivne simulacije za pojmove koji se odnose na oruđa i koja pokušava angažirati iste resurse koji su aktivni i kod izvođenja radnje. Na kraju treba spomenuti da se efekt perceptivne simulacije javlja ne samo kod obrade pojedinačnog pojma već i u situaciji kada ispitanici moraju kreirati pojmovne kombinacije (Wu i Barsalou, 2009).

1.1.4. Pojmovi i prostor

Pamćenje lokacija u okolini gdje se nalaze relevantni objekti od velike je evolucijske važnosti. Znanje o tome gdje se može pronaći hrana ili gdje treba posebno paziti na opasnost, povećava šanse za opstanak (Coslett, 1999). Zbog toga je veliki dio mozga zadužen za konstrukciju mentalne reprezentacije prostora uključujući dijelove temporalnog, parijetalnog i prefrontalnog korteksa te dijelove bazalnih ganglija i talamusa na subkortikalnoj razini (Chatterjee, 2001).

Prema hipotezi o prostornoj registraciji, informacija o prostornoj lokaciji se automatski kodira u pamćenju i kasnije može stupiti u interakciju s drugim kognitivnim funkcijama kao što su planiranje akcije ili jezik, iako ona nije direktno relevantna za tekući zadatak. Prema ovom gledištu, veza između lingvističke reprezentacije i reprezentacije položaja u prostoru ostvaruje se pomoću usmjeravanja pažnje na prostornoj mapi. Pažnja povezuje prostornu poziciju s apstraktnim simbolom tako da stvara znak (token) ili pokazivač (pointer) koji specificira koordinate relevantnog objekta. Glavna pretpostavka prostorne registracije je da je pozicijski znak povezan sa svim modulima za obradu informacija uključujući osjetne, motorne i lingvističke module. Kada učimo značenje nove riječi koja označava neki objekt, simbolička reprezentacija (riječ) tog objekta je povezana s osjetnim svojstvima danog objekta uključujući i njegovu tipičnu poziciju u prostoru s obzirom na opažača. Veza se uspostavlja putem pozicijskog znaka na prostornoj mapi. Posljedica aktivacije određenog pozicijskog znaka je brža obrada svih informacija (objekata, riječi) vezanih uz taj znak.

Hipoteza o prostornoj registraciji usko je povezana s konceptom mreže riječi (*word web*) kojeg je predložio Pulvermüller (1999; 2001). On je predložio da se tijekom leksičke

obrade aktivira distribuirana mreža neurona u različitim osjetnim, motornim i jezičnim područjima korteksa, koja odgovaraju osjetnim, motornim i jezičnim reprezentacijama danog pojma. Na primjer, kada čujemo riječ auto, mrežna aktivnost se širi prema osjetnim područjima čime se iz pamćenja dozivaju osjetna svojstva tipičnog automobila (oblik, boja). Aktivnost se također širi i na motorna područja čime se reaktiviraju tipične radnje vezane uz auto (vožnja). Mreža riječi nastaje mehanizmima asocijativnog ili korelacijskog učenja (Hebbovo pravilo za stvaranje veza među neuronima) koji povezuju i koordiniraju neuronsku aktivnost u različitim dijelovima korteksa.

Kada mehanizmi pažnje ne funkcioniraju pravilno (zbog ozljede), hipoteza o prostornoj registraciji predviđa da će i jezična funkcija također biti oštećena. Potvrdu za ovu ideju pronašao je Coslett (1999) u istraživanju neuroloških pacijenata s ozljedom parijetalnog korteksa. Zna se da je parijetalni korteks uključen u konstrukciju prostorne reprezentacije i u procese usmjeravanja prostorne pažnje (Colby i Goldberg, 1999). Međutim, pacijenti s ozljedom parijetalnog korteksa pokazali su i teškoće u izvođenju leksičkih zadataka (leksički doziv, semantičko pretraživanje), ovisno o položaju podražaja u vidnom polju. Pacijenti s ozljedom lijevog parijetalnog korteksa pokazali su lošiju izvedbu na leksičkim zadacima kada im je pažnja usmjerena u desni dio vidnog polja. S druge strane, pacijenti s ozljedom desnog parijetalnog korteksa pokazali su lošiju izvedbu kada im je pažnja bila usmjerena u lijevi dio vidnog polja. Iz ovih rezultata može se zaključiti da parijetalni korteks, pored poznate uloge u usmjeravanju pažnje i reprezentaciji prostora ima utjecaja i na leksičku obradu.

Richardson, Spivey, Barsalou i McRae (2003) su ispitali postoji li povezanost između prostorne reprezentacije i glagola. Koristeći zadatke vidne diskriminacije i vidnog pamćenja oni su pokazali da postoji interakcija između tipične orijentacije radnje koju označava neki glagol i orijentacije podražaja koji je prikazan. Na primjer, glagol gurati je povezan s horizontalnom orijentacijom jer se objekti koje guramo obično nalaze u istoj ravnini kao i izvođač radnje. S druge strane, glagol poštovati je povezan s vertikalnom orijentacijom, jer osobu koju poštujemo doživljavamo kao iznad sebe. Kod zadatka vidne diskriminacije, ispitanici su čitali i pamtili kratke rečenice nakon čega su trebali identificirati vidno prezentirani podražaj kao krug ili kvadrat. Vidni podražaj je mogao biti prezentiran na četiri položaja na ekranu: gore, dolje, lijevo i desno od fiksacijske točke koja je uvijek bila u središtu ekrana. Rezultati su pokazali da je prezentacija glagola s vertikalnom orijentacijom dovela do interakcije s položajem objekta uzduž vertikalne dimenzije (gore ili dolje od fiksacijske točke). Međutim, kada je prezentiran glagol s horizontalnom orijentacijom, nije

došlo do interakcije s položajem objekta uzduž horizontalne dimenzije. Slični rezultati dobiveni su i u zadatku vidnog pamćenja. Rezultati istraživanja Richardsona i sur. (2003) su u skladu sa perceptivno-motornim karakterom lingvističkih reprezentacija. Zanimljivo je da to vrijedi čak i za apstraktne glagole kao što je glagol poštovati.

Zwaan i Yaxley (2003) su željeli ispitati kako relativni položaj riječi može utjecati na prosudbu o semantičkoj povezanosti riječi. U istraživanju su koristili parove riječi koje označavaju objekte koji se međusobno nalaze u vertikalnom prostornom odnosu. Riječi su prezentirane jedna ispod druge pri čemu je u jednom slučaju prostorni odnos riječi odgovarao stvarnom prostornom odnosu objekata koje te riječi označavaju kao na primjer:

NEBO

ZEMLJA

U drugom slučaju riječi su bile prezentirane u suprotnom prostornom odnosu s obzirom na objekte koje označavaju kao kod:

PODRUM

KROV

Zadatak ispitanika je bio da odrede jesu li dvije prezentirane riječi semantički povezane ili nisu. Polovica podražajnih parova su bile riječi koje nisu semantički povezane. Rezultati su pokazali da je vrijeme potrebno za donošenje odluke kraće kod semantički povezanih riječi ako su prezentirane u prostornom odnosu koji odgovara prostornom odnosu objekata koje označavaju. Ovaj efekt Zwaan i Yaxley (2003) nazvali su efekt prostorne ikoničnosti. Međutim, oni nisu bili u mogućnosti kontrolirati kako se pažnja distribuira u vidnom polju što je važno za aktivaciju pozicijskih znakova (pokazivača). Razumno je pretpostaviti da su ispitanici čitali riječi odozgo prema dolje. Isto tako, moguće je da ljudi konstruiraju mentalne reprezentacije objekata u prostoru krećući se odozgo prema dolje. Dakle, duže vrijeme

odlučivanja za obrnuti raspored riječi i njihovih referenata može se pripisati kršenju uobičajenog temporalnog poretka dozivanja leksičkih i semantičkih informacija zasnovanih na vezama s prostornim znakovima. Zwaan i Yaxley (2003) su isključili ovu mogućnost tako što su pokazali da se efekt prostorne ikoničnosti ne javlja kada su riječi prezentirane horizontalno.

U istraživanju koje su proveli Šetić i Domijan (2007) pokazalo se da vertikalna pozicija prikazane riječi utječe na brzinu verifikacije svojstva. Ispitanicima je usmjeravana pažnje na gornji ili donji dio ekrana nakon čega je na tom mjestu prezentirana riječ koja označava životinju koja leti (galeb, orao) ili životinju koja ne leti (pas, mačka). Zadatak ispitanika bio je da odrede označava li riječ životinju koja leti ili ne leti. Osnovna ideja je bila da će usmjeravanje pažnje prema gore ili dolje olakšati ili ubrzati perceptivnu simulaciju pojmova čije referentne objekte tipično susrećemo u gornjem ili donjem dijelu vidnog polja. Rezultati su doista pokazali da je verifikacija bila brža za riječi za leteće životinje kada su prikazane u gornjem dijelu ekrana i za riječi za životinje koje ne lete kada su prikazane u donjem dijelu ekrana. U drugom eksperimentu pokazano je da se isti efekt javlja i kada su ispitanici verificirali označava li prikazana riječ živo biće ili neživu stvar, pri čemu su kao podražaji korištene riječi za životinje kao u prvom eksperimentu i riječi za stvari koje povezujemo s gornjim (šešir, oblak) ili donjim (cipela, pločnik) dijelom vidnog polja.

Problem s rezultatom kojeg su dobili Šetić i Domijan (2007) je da se on može interpretirati i u okviru teorije o korespondenciji polariteta (Lakens, 2011; Proctor i Cho, 2006). Naime, odgovori u zadatku verifikacije (da ili ne) direktno su preslikani na semantičke kategorije koje treba razlikovati (leti ili ne leti). Drugim riječima, ispitanici su uvijek odgovarali s *da* na riječi za životinje koje lete pa je moguće da je došlo do strukturalne usklađenosti između podražaja i odgovora (da - leti; ne - ne leti) koja je ubrzala vrijeme verifikacije. Međutim, Pecher, van Dantzig, Boot, Zanolie i Huber (2010) su otklonili ovakvu interpretaciju korištenjem zadatka u kojem se tražilo da se odredi da li se riječ referira na objekt kojeg tipično srećemo na nebu (avion). U drugom zadatku tražilo se da se odredi da li se riječ referira na objekt kojeg tipično srećemo u oceanu (podmornica). Kada se direktno usporede rezultati u ova dva zadatka pokazalo se da se brže reagira na riječ kao što je avion kada je prikazana u gornjem dijelu ekrana nego u donjem. S druge strane, na riječ kao što je podmornica reagira se brže kada je prikazana u donjem dijelu ekrana nego u gornjem. Ovaj efekt se javlja neovisno o tome što se u dva zadatka odgovara različito na istu riječ što upućuje na zaključak da je perceptivna simulacija bolje objašnjenje opisanih efekata od

korespondencije polariteta (van Dantzig i Pecher, 2011). Međutim, treba spomenuti da se ne slažu svi s ovim zaključkom (Lakens, 2011).

1.1.5. Razumijevanje jezika

1.1.5.1. Prožeti iskustvenik

Teorija perceptivnih simboličkih sustava usmjerena je ponajprije na razumijevanje pojedinačnog pojma. Međutim, to nije dovoljno za razumijevanje većih značenjskih jedinica kao što su rečenice i tekstovi. Drugim riječima, za razumijevanje značenja rečenice nije dovoljno samo dozvati iz semantičkog pamćenja značenje svih riječi od koje se rečenica sastoji. Kako bi precizirao ulogu perceptivne simulacije u razumijevanju jezika, Zwaan (2004) je razvio novi teorijski okvir kojeg je nazvao prožeti iskustvenik (*immersed experiercer*). Osnovna ideja ovog modela je da riječi aktiviraju različita upamćena iskustva povezana s objektima koje te riječi označavaju (referenti). Okvir prožetog iskustvenika razlikuje tri procesa koja se aktiviraju tijekom razumijevanja jezika. To su:

1. Aktivacija
2. Konstrukcija značenja
3. Integracija

Čitanjem ili slušanjem, riječi aktiviraju leksičke, gramatičke i fonološke reprezentacije, ali isto tako aktiviraju i iskustvene reprezentacije svojih referenata. Te iskustvene reprezentacije mogu biti motorne, perceptivne, emocionalne, a često se mogu javiti i u nekoj kombinaciji. Iskustveni tragovi se aktiviraju putem verbalnog podražaja i omogućuju rekonstrukciju doživljaja. U tom smislu, razumijevanje je zamjensko ili naknadno doživljavanje opisanih događaja kroz integraciju tragova iz stvarnih doživljaja potaknuto lingvističkim podražajima. U Tablici 1. navedeni su procesi razumijevanja jezika zajedno s lingvističkim i reprezentacijskim jedinicama nad kojima operiraju, kao i referentnih jedinica koje označavaju.

Tablica 1.1. *Komponente procesa razumijevanja*

Proces	Lingvistička jedinica	Reprezentacijska jedinica	Referentna jedinica
Aktivacija	Riječ/morfem	Funkcionalne mreže	Objekti i akcije
Konstrukcija značenja	Rečenica/Intonacijska jedinica	Integrirane mreže	Događaji
Integracija	Povezani diskurs	Niz integriranih mreža	Niz događaja

Komponentni procesi razumijevanja ne operiraju sekvencijalno jedan iza drugog, već ih treba shvatiti kao međusobno povezane procese između kojih postoji veliko temporalno preklapanje. U Tablici 1. su prikazane i lingvističke jedinice koje predstavljaju ulaznu informaciju za svaki proces. Pretpostavka je da su riječi povezane s nizom iskustvenih tragova vezanih uz njihove referente. Takav skup tragova naziva se funkcionalna mreža. Funkcionalnu mrežu čini cijeli niz kortikalnih centara uključujući i primarna osjetna i motorna područja koja se aktiviraju tijekom prezentacije riječi (Pulvermüller, 2002). Referentne jedinice odnose se na objekte ili događaje u okolini koji su povezani s reprezentacijskim jedinicama.

Na primjer, rečenica *Izviđač je vidio orla na nebu* aktivira vidno iskustvo izviđača, orla i neba. Međutim, perceptivne simulacije ova tri pojma nisu izolirane nego se integriraju u događaj viđenja orla kako leti na nebu. Pri tome, aktiviraju se različite iskustvene informacije koje nisu direktno dane u samoj rečenici nego su implicirane situacijom koju rečenica opisuje. Najočitija informacija koja nam prva pada na pamet kada pročitamo rečenicu je da se radi o događaju koji se odvija u šumi, a ne u gradu. Iz toga proizlazi cijeli niz dodatnih zaključaka. Izviđač vjerojatno ima šešir i gojzerice budući da ove rekvizite često nose posjetitelji šuma. Nadalje, orao ima raširena krila budući da leti, ima perje i glasa se kliktanjem. Ključni aspekt prožetog iskustvenika je da mala promjena u rečenici može bitno promijeniti simulaciju događaja. Na primjer, rečenica *Izviđač je vidio orla u gnijezdu* ponovno aktivira vidno

iskustvo izviđača i orla, ali sada imamo novi pojam - gnijezdo. Prilikom integracije perceptivnih simulacija u događaj, u ovom slučaju stvara se mentalna slika orla u gnijezdu. Pri tome su orlu krila skupljena, a ne raširena kao u prethodnoj rečenici. Na taj način, dvije rečenice impliciraju dva različita položaja koja zauzima isti referent (orao) i time ostavljaju dva različita iskustvena traga. Važno je naglasiti da nijedan od ovih zaključaka izvedenih iz simulacije događaja nisu eksplicitno dani u rečenici. Prema amodalnoj reprezentaciji znanja, položaj (ili bilo koji drugi perceptivni aspekt) referentnog objekta nebitan je za razumijevanje, osim ako nije direktno opisan riječima u rečenici.

1.1.5.2. Indeksna hipoteza

Slično prožetom iskustveniku, indeksna hipoteza koju su predložili Glenberg i Robertson (1999; Kaschak i Glenberg, 2000) utemeljuje razumijevanje značenja rečenica u senzorno-motornom iskustvu. Prema indeksnoj hipotezi postoje tri procesa koja određuju razumijevanje rečenice. Prvi proces je indeksiranje (preslikavanje) riječi i fraza u rečenici na referente u okolini ili na mentalne reprezentacije kao što su perceptivne simulacije (Barsalou, 1999). Indeksiranje određuje sadržaj jezika, odnosno odgovara na pitanje o kome ili o čemu se govori u rečenici. Drugi proces je određivanje afordansi (*affordances*) iz indeksiranih referenata. Afordanse su pojam iz direktne teorije percepcije (Gibson, 1979) kojim se označava što opažaču pružaju objekti koje percipira. Na primjer, afordansa stolice je da na njoj možemo sjediti, afordansa jabuke je da ju možemo pojesti ili ju možemo dati nekom drugom, a afordansa štapa je da njime možemo gurati drugi objekt, možemo se na njega osloniti ili možemo njime pokazivati. Drugim riječima, afordanse opisuju načine na koje možemo stupati u interakciju s objektima u okolini. Ovisno o našim ciljevima različite afordanse istog objekta mogu iskočiti u prvi plan. Ako smo uganuli nogu, tada nam u prvi plan dolazi svojstvo štapa da se na njega možemo osloniti. S druge strane, ako želimo pogurati neki objekt kroz procjep onda nam u prvi plan dolazi drugo svojstvo štapa, tj. njegova dužina zbog čega nam može poslužiti za guranje. Treći proces je preplitanje afordansi pod kontrolom intrinzičnih ograničenja i ograničenja proizašlih iz sintakse. Preplitanje je proces kojim se afordanse kombiniraju u koherentne uzorke tj. akcije koje se mogu izvesti kako bi se ostvario cilj. Preplitanje afordansi za štap, jabuku i procjep omogućuje nam razumijevanje rečenice kao što je *Lidija je gurnula štapom jabuku kroz procjep*. Preplitanje

poštuje intrinzična biološka i fizička ograničenja tako da nam rečenica *Lidija je gurnula koncem jabuku kroz procjep* nema smisla jer se afordansa konca ne uklapa u radnju guranja. Sintaksa rečenice također ograničava preplitanje tako što pruža znakove koji omogućuju strukturiranje generalne situacije ili događaja koji se opisuje u rečenici.

1.1.5.3. Jezik i perceptivna simulacija

Stanfield i Zwann (2001) su proveli jedno od prvih istraživanja u kojima su pokazali da se perceptivna simulacija automatski aktivira tijekom obrade rečenice i kreira mentalni model situacije opisane u rečenici. Ispitanici su rješavali zadatak usporedbe rečenice i slike pri čemu su morali odrediti odgovara li objekt prikazan na slici objektu spomenutom u rečenici. Rezultati su pokazali kraće vrijeme usporedbe kada se orijentacija objekta na slici podudarala s orijentacijom koja se implicira u rečenici. Na primjer, ako rečenica govori o čavlu koji je zabijen u zid nastaje perceptivna simulacija čavla koji je okrenut vodoravno što se manifestira kao kraće vrijeme potrebno za prepoznavanje čavla kada je orijentiran u istom smjeru kao što implicira rečenica nego u nekom drugom smjeru. S druge strane, ako rečenica govori o čavlu koji je zabijen u pod nastaje perceptivna simulacija čavla koji je okrenut okomito. Zanimljivo je da su Stanfield i Zwaan (2001) mjerili brzinu rješavanja zadataka mentalne rotacije kod istih ispitanika te pokazali da postoji pozitivna korelacija između brzine mentalne rotacije i brzine rješavanja zadatka usporedbe rečenice i slike što daje dodatnu potvrdu za ulogu percepcije u nastanku opisanog efekta. U sličnom istraživanju, Zwann, Stanfield i Yaxley (2002) su pokazali da rečenica koja implicira određeni oblik objekta olakšava prepoznavanje tog objekta ako slika objekta odgovara situaciji u rečenici. Na primjer, u rečenici u kojoj se implicira da ptica ima raširena krila jer leti, brže je vrijeme reakcije na sliku ptice s raširenim krilima, nego na sliku ptice sa skupljenim krilima. S druge strane, ako rečenica implicira da ptica ima skupljena krila jer je sletjela u gnijezdo dobiva se obrnuti uzorak, tj. kraće je vrijeme potrebno da se prepozna ptica sa skupljenim krilima, nego ptica s raširenim krilima. Nedavno su Zwaan i Pecher (2012) replicirali nalaze o perceptivnoj simulaciji orijentacije i oblika objekta na kojeg se referira u rečenici koristeći veliki uzorak ispitanika koje su regrutirali putem Interneta. Ovakvi rezultati direktno proizlaze iz teorijskog okvira prožetog iskustvenika i ne mogu se lako interpretirati u okviru statističkih i drugih amodalnih teorija reprezentacije znanja.

Perceptivna simulacija ne mora biti statična već može uključivati reaktivaciju temporalnog uzorka odnosno kretanja. Koristeći sličnu logiku kao i u prethodno opisanim istraživanjima, Zwaan, Madden, Yaxley i Aveyard (2004) su ispitali da li će razumijevanje rečenica koje uključuju opis kretanja objekta u određenom smjeru utjecati na percepciju stvarnog kretanja objekta u istom smjeru. U istraživanju su korištene rečenice kao:

Suigrač ti je dodao loptu.

ili

Ti si dodao loptu suigraču.

Rečenice su prezentirane auditorno preko slušalica. Nakon što je rečenica izgovorena, na ekranu bi se jedna iza druge pojavile dvije slike. Slike su mogle prikazivati isti objekt ili dva različita objekta. Zadatak ispitanika je bio da odgovori da li slike prikazuju isti objekt ili različite objekte. U situaciji kada su slike prikazivale isti objekt, u jednom slučaju je prva slika bila manja od druge slike. Na taj način, inducirao se dojam kretanja objekta prema ispitaniku (prividno kretanje). U drugom slučaju je prva slika bila veća od druge čime se inducirao dojam udaljavanja objekta od ispitanika. Rečenica koja je prethodila prezentaciji objekta mogla je govoriti o smjeru kretanja koji je konzistentan sa smjerom kretanja objekta na slikama ili koji je suprotan od smjera kretanja objekta na slikama. Rezultati su pokazali da je vrijeme potrebno da se riješi perceptivni zadatak kraće kada rečenica govori o istom smjeru kretanja koji je prikazan na slikama nego u situaciji kada rečenica govori o suprotnom smjeru kretanja od onog prikazanog na slikama. Time su Zwaan i sur. (2004) pokazali da se tijekom obrade rečenica aktivira i sustav za percepciju pokreta. Zanimljivo je da su u sličnom istraživanju, Kaschak i sur. (2005) dobili suprotne rezultate. Naime, brže se reagiralo na rečenice koje govore o pokretu u suprotnom smjeru od onog koji je prikazan na ekranu. Međutim, u ovom istraživanju rečenice su prezentirane na isti način, ali je pokret bio prikazan istovremeno s prezentacijom rečenica, a ne nakon nje. Zadatak ispitanika je bio da odrede je li rečenica smisljena. Kaschak i sur. (2005) su interpretirali ove rezultate kao još jednu potvrdu

za teoriju o perceptivnoj simulaciji zato jer se u ova dva istraživanja radi o dva različita aspekta perceptivne simulacije. U istraživanju Zwaana i sur. (2004) ispitivalo se kakve posljedice na percepciju pokreta ima prethodna perceptivna simulacija koja se odvijala prije same percepcije. U tom slučaju tragovi prethodne simulacije poboljšali su (ili olakšali) percepciju pokreta u istom smjeru. Međutim, u istraživanju Kaschaka i sur. (2005) perceptivna simulacija i percepcija su se odvijale istovremeno zbog čega je došlo do interferencije odnosno percepcija kretanja u određenom smjeru ometala je izvođenje perceptivne simulacije u istom smjeru kretanja. Dakle i percepcija i perceptivna simulacija koriste isti reprezentacijski format, što je u skladu s postavkama teorije o perceptivnim simboličkim sustavima.

Na sličan način kao i s perceptivnim iskustvom, jezik je povezan i s motornim radnjama. U istraživanju koje su proveli Glenberg i Kaschak (2002) od ispitanika se tražilo da odgovore na pitanje da li je rečenica smisljena ili nije. Na primjer korištene su rečenice kao:

Iva ti je dodala pizzu.

ili

Je Iva dodala ti pizzu.

Iako to nije bilo relevantno za sam zadatak koji su rješavali ispitanici, polovica smislenih rečenica je opisivala radnju koja se odvija prema ispitaniku, a druga polovica je opisivala radnju koja se odvija od ispitanika (npr. Ti si dodao Ivi pizzu). U jednom uvjetu ispitanici su morali odgovoriti da li je rečenica smisljena tako da povuku ručicu uređaja za mjerenje vremena reakcije prema sebi, a u drugom uvjetu su morali povlačiti ručicu uređaja od sebe kada je rečenica bila smisljena. Rezultati su pokazali da se javila interakcija između impliciranog smjera kretanja u rečenici i stvarnog kretanja rukom koje su morali napraviti ispitanici kako bi odgovorili na zadatak. Drugim riječima, ispitanici su brže reagirali kada je smjer kretanja ruke (prema ili od vlastitog tijela) odgovarao smjeru kretanja koji se implicira

u rečenici. Ovaj rezultat nazvan je efekt kompatibilnosti između radnje i rečenice (*action sentence compatibility effect*). Na taj način, Glenberg i Kaschak (2002) su pokazali da su i motorne informacije dostupne tijekom obrade rečenica odnosno da se u procesu konstrukcije značenja rečenice dozivaju i prostorne i funkcionalne informacije koje su vezane uz motorni sustav.

Nadalje, efekti perceptivne simulacije mogu se pojaviti i u kompleksnijim situacijama koje uključuju integraciju percepcije i motorike kao što je zauzimanje perspektive. Osnovna hipoteza je da doziv informacija o dijelovima nekog objekta ovisi o njihovoj prostornoj organizaciji i o funkcionalnoj perspektivi iz koje se objekt promatra. Na primjer, kada razmišljamo o automobilu, što ćemo konkretno dozvati iz pamćenja ovisi o tome koju perspektivu zauzmemo, tj. da li razmišljamo o perspektivi kako vozimo automobil ili o perspektivi kako punimo automobil gorivom. Ovu pretpostavku ispitali su Borghi, Glenberg i Kaschak (2004) u istraživanju u kojem su ispitanicima bile prezentirane rečenice tipa:

Jedeš u restoranu.

Čekaš ispred restorana.

ili

Krećeš se prema restoranu i ulaziš u njega.

Ovakve rečenice manipulirale su perspektivu iz koje se promatra određeni objekt (u ovom slučaju restoran) tako da ga se može promatrati iznutra, izvana ili iz kombinirane perspektive. Nakon rečenice ispitanicima je bila prezentirana testna riječ koja je označavala dio objekta o kojem se govori u prethodnoj rečenici ili neka riječ nevezana za objekt. Od riječi koje su označavale dijelove objekta neke su bile vezane za unutrašnjost objekta (stol), dok su druge

bile više vezane za vanjštinu objekta (znak). Zadatak ispitanika je bio da odgovore označava li prezentirana riječ dio objekta. Rezultati su pokazali značajnu interakciju između perspektive (unutra ili van) i položaja dijela objekta (unutra ili van). Kada zauzmemo perspektivu u kojoj objekt gledamo iznutra tada je lakše riješiti zadatak za dio objekta koji se nalazi unutra. S druge strane, kada zauzmemo perspektivu u kojoj gledamo objekt izvana, lakše je riješiti zadatak za dio objekta koji se nalazi izvana. Na taj način, Borghi i sur. (2004) su pokazali da kombinirane perceptivne i motorne reprezentacije (zauzimanje perspektive) imaju važnu ulogu kod doziva pojmovnog znanja tijekom obrade rečenica.

Perceptivna simulacija se može generalizirati i na internalna stanja pa stoga možemo očekivati da će trenutno emocionalno stanje utjecati na obradu emocionalno obojenih rečenica. Koristeći proceduru za manipulaciju raspoloženjem Glenberg, Havas, Becker i Rinck (2005) su pokazali da ispitanici brže reagiraju na pozitivno obojene rečenice kada su i sami u pozitivnom raspoloženju, a na negativno obojene rečenice kada su u negativnom raspoloženju. Raspoloženje je manipulirano tako da se od ispitanika tražilo da, dok čitaju rečenice, drže olovku u ustima na jedan od dva načina: zubima ili usnama. Držanje olovke zubima stvara facijalnu ekspresiju sličnu smijehu što putem povratnih veza od mišića lica prema mozgu inducira pozitivno raspoloženje. Nasuprot tome, držanje olovke usnama inducira negativno raspoloženje jer se pri tome stvara facijalna ekspresija slična tuzi. Iz toga se može zaključiti da mehanizam perceptivne simulacije pristupa reprezentaciji emocionalnih stanja na isti način kao što pristupa i osjetnim sustavima.

1.1.6. Utjelovljenje u socijalnoj psihologiji

U socijalnoj psihologiji postoji duga tradicija istraživanja utjecaja tijela na ponašanje, emocije i stavove ljudi koja se razvijala neovisno od trendova u kognitivnoj psihologiji (Meier, Schall, Schwartz i Bargh, 2012). Na primjer, Solarz (1960) je pokazao da ispitanici brže pokreću ruku prema sebi nego od sebe kada gledaju riječ pozitivnog značenja. S druge strane, kada gledaju riječ negativnog značenja, brže pokreću ruku od sebe nego prema sebi što znači da pokreti privlačenja i odgurivanja postaju sastavni dio naših afektivnih evaluacija. Slično tome, Wells i Petty (1980) su otkrili da ljudi koji vertikalno klimaju glavom pokazuju veću tendenciju da se slože s porukom od ljudi koji klimaju glavom horizontalno budući da je vertikalno klimanje glavom znak odobravanja, a horizontalno klimanje znak neodobravanja.

Strack, Martin i Stepper (1988) su otkrili da ljudi ocjenjuju stripove kao smješnije kada drže olovku zubima nego kada ju drže usnama. Kao što je opisano u prethodnom poglavlju, držanje olovke zubima inducira pozitivno raspoloženje, a držanje olovke usnama inducira negativno raspoloženje. U zadnje vrijeme posebna pažnja je posvećena istraživanju kako se emocije i socijalne situacije mogu razumjeti putem metaforičkog preslikavanja na percepciju, motoriku i tjelesna stanja (Landau, Meier i Keefer, 2010).

Afektivno obojene riječi mogu se metaforički preslikati na boje odnosno na dimenziju svjetline (crno-bijelo). Meier, Robinson i Clore (2004) su kreirali listu od 50 pozitivnih i 50 negativnih riječi koje su bile prikazane na ekranu u bijeloj ili crnoj boji. Riječi su bile prezentirane jedna iza druge, a zadatak ispitanika je bio odrediti valenciju dane riječi odnosno odrediti je li riječ pozitivna ili negativna. Rezultati su pokazali da su ispitanici brže odgovarali kada je pozitivna riječ bila prikazana u bijeloj nego u crnoj boji. S druge strane, odgovarali su brže na negativne riječi kada su bile prikazane u crnoj nego u bijeloj boji. Meier i sur. (2004) su zaključili da afektivna evaluacija riječi aktivira metaforički konzistentnu reprezentaciju akromatske boje (dobro-bijelo, loše-crno). U sljedećoj studiji, Meier, Robinson, Ceawford i Ahlvers (2007) su pokazali da afektivna evaluacija riječi direktno mijenja percepciju svjetline jer su pozitivne riječi procijenjene kao svjetlije nego negativne riječi iako su otisnute istom nijansom sive boje. Meier i Robinson (2005) zaključuju da ovakav efekt nije slučajan već da mnoge kulture i religije povezuju svjetlo s dobrim, a mrak s lošim. U filmovima su često pozitivni likovi obučeni u svijetlu odjeću, a negativni likovi u tamnu kao recimo u Ratovima zvijezda. Sportaši obučeni u tamnije dresove više se percipiraju kao agresivni i češće im se sudi prekršaj, nego sportašima u svjetlijim dresovima. I djeca pokazuju tendenciju da u bijeloj košari očekuju pozitivan objekt (lizalicu), a u crnoj košari negativan (blato). Nadalje, Sherman i Clore (2009) su pokazali da se bijela boja automatski doživljava kao perceptivni simbol moralne čistoće, a crna boja kao simbol nemoralna.

Afektivno obojene riječi automatski se preslikavaju i na vertikalnu dimenziju prostora, pri čemu se pozitivne riječi povezuju s gornjim dijelom, a negativne riječi s donjim dijelom prostora (Meier i Robinson, 2004). Ovaj efekt vjerojatno proizlazi iz činjenice da je pozitivno raspoloženje povezano s uspravnim položajem tijela, a negativno raspoloženje s pogrbljenim položajem (Meier i Robinson, 2005). Emocionalni izrazi se preslikavaju i na doživljaj temperature pri čemu se pozitivne emocije povezuju s toplinom kao u izrazima kao što su: *Ona je topla i draga osoba* ili *Pružili smo im toplu dobrodošlicu*. S druge strane, negativne emocije se povezuju s hladnoćom kao u izrazima kao što su: *Dočekao ih je hladan prijem* ili

Doživjeli su hladan tuš. Empirijsku potvrdu ove veze pružili su Williams i Bargh (2008) koji su dali ispitanicima da prije početka istraživanja drže u rukama šalicu tople ili hladne kave. Nakon toga, tražili su od ispitanika da procjene osobine ličnosti neke imaginarne osobe. Dobili su da su oni ispitanici koji su držali šalicu tople kave procjenjivali imaginarnu osobu kao topliju i prijateljskiju od ispitanika koji su prethodno držali šalicu hladne kave što je u skladu s metaforičkom vezom između emocija i temperature. Nadalje, Zhong i Leonardelli (2008) su tražili od ispitanika da se prisjete neke situacije iz svog života kada su bili socijalno prihvaćeni ili odbačeni. Ispitanici koji su se prisjećali ugodnog doživljaja procjenjivali su toplinu sobe u kojoj se nalaze za 5° toplijom od ispitanika koji su se prisjećali neugodnog doživljaja odbacivanja.

Istraživanja također pokazuju da se i moralnost može razumjeti putem metaforičkog preslikavanja na tjelesna stanja. Zhong i Liljenquist (2006) su dobili da su ispitanici, od kojih se tražilo da razmišljanju o moralnim prijestupima kao što su preljub ili prijevara, u većoj mjeri tražili antiseptičke maramice nakon provođenja pokusa nego ispitanici koji su zamišljali dobra djela. Iz toga proizlazi da ispitanici metaforički shvaćaju moralni prijestup kao fizičku nečistoću od koje se žele oprati. Isto tako, izvršenje moralnog prijestupa (od ispitanika se tražilo da lažu) povećava potrebu za higijenskim proizvodima i povećava spremnost da se za njih plati. Zanimljivo je da je ovaj efekt specifičan za modalitet kojim je počinjen moralni prijestup. Kada su ispitanici rekli laž, kod njih se povećala potreba za korištenjem vodice za ispiranje usta, ali ne i antiseptičkih maramica. Međutim, kada su laž morali napisati rukom kod ispitanika se pojačala potreba za korištenjem maramica (Lee i Schwartz, 2010a). Pranje ruku moglo bi biti općenitiji mehanizam metaforičkog brisanja tragova prošlosti. Lee i Schwartz (2010b) su otkrili da pranje ruku nakon zadatka donošenja odluka dovodi do smanjenja kognitivne disonance odnosno do manje promjene u afektivnoj evaluaciji alternativa između kojih se bira. Svi ovi primjeri ukazuju na činjenicu da utjelovljenje igra važnu ulogu u razumijevanju emocija i socijalnog svijeta (Landau i sur., 2010; Meier i sur., 2012).

1.1.7. Edukacija i utjelovljenje

Ideja da konkretno iskustvo potiče učenje i stjecanje znanja prisutna je u edukacijskog psihologiji odavno. Međutim, teorijski okvir utjelovljene spoznaje pruža objašnjenje zašto bi takav efekt postojao odnosno daje specifičan mehanizam putem kojeg iskustvo djeluje na učenje. Nadalje, utjelovljenje pruža inspiraciju za osmišljavanje edukacijskih intervencija koje mogu unaprijediti poučavanje od elementarnih vještina kao što je čitanje do usvajanja apstraktnog gradiva matematike, fizike i kemije (Kontra, Goldin-Meadow i Beilock, 2012).

Glenberg, Gutierrez, Levin, Japuntich i Kaschack (2004) su pokazali da manipulacija objekata kao i zamišljanje manipulacije značajno poboljšava razumijevanje pročitanoog teksta kod djece u prvom razredu osnovne škole. Oni su osmislili metodu poučavanja čitanja koja uključuje baratanje s igračkama (ili zamišljanje) koje predstavljaju objekte koji se spominju u rečenicama. Na primjer, djeca su imala priliku baratati s igračkama konja i traktora kada su čitala tekst o seoskoj farmi. Razumijevanje je ispitano testom pamćenja o pročitanoom tekstu kao i testom izvlačenja zaključaka iz pročitanoog teksta. Rezultati su pokazali da su djeca koja su baratala s objektima pokazala 78% bolje rezultate, a djeca koja su zamišljala baratanje objektima čak 99% bolje rezultate od djece koja su samo čitala tekst. Glenberg i sur. (2004) objasnili su ove rezultate u okviru indeksne hipoteze jer baratanje objektima potiče ispravno indeksiranje između riječi u tekstu i referentnih objekata.

Goldin-Meadow, Cook i Mitchell (2009) su manipulirali gestikulacijom učenika dok uče lekciju o matematičkoj jednakosti. Učenici su rješavali zadatke tipa: $3 + 5 + 8 = ___ + 8$. Učenici su bili podijeljeni u tri grupe s obzirom na gestikulaciju rukama koju su morali napraviti tokom usvajanja gradiva. Jedna grupa rješavala je zadatak bez gestikulacije. Druga grupa je trebala saviti prste u obliku slova V te ih postaviti tako da vršci prstiju obuhvaćaju brojeke 3 i 5 (ispravna gestikulacija) a zatim pokažu na prazno mjesto u jednadžbi. Treća grupa je također savila prste u obliku slova V ali je morala prste postaviti tako da vršci prstiju obuhvaćaju brojeke 5 i 8 (djelomično ispravna gestikulacija). Tokom vježbanja učenici nisu dobivali povratnu informaciju o svom uratku. Nakon faze učenja uslijedio je test u kojem su učenici trebali dati odgovor na postavljeni zadatak i objasniti kako su došli do rješenja. Rezultati su pokazali da su učenici koji su radili ispravnu gestikulaciju pokazali najbolje rezultate, učenici koji su radili djelomično ispravnu gestikulaciju pokazali su lošiji uradak, a najslabiji su bili učenici koji nisu uopće gestikulirali. Zanimljivo je da je ovaj efekt u

potpunosti posredovan strategijom grupiranja koju su usvojili putem gestikuliranja u fazi učenja.

Iako utjelovljena spoznaja pruža brojne ideje kako unaprijediti poučavanje u školi, neki autori upozoravaju na zamke i opasnosti ovakvog pristupa (McNeil i Uttal, 2009; Mix, 2010; Sarama i Clements, 2009). Na primjer, djeca mogu postati previše okupirana nebitnim detaljima situacije što ih može spriječiti u generaliziranju naučenog gradiva na nove situacije (McNeil, Uttal, Jarvin i Sternberg, 2009) ili mogu svoje iskustvo s objektima shvatiti kao relevantno samo za te konkretne objekte (Uttal, Scudder i DeLoache, 1997). Drugim riječima, utjelovljenje može pomoći u rješavanju konkretnog problema, ali može postati kočnica kada treba naučeno znanje primijeniti na nove probleme. Kao mogući odgovor na ove kritike, Novack, Congdon, Hemani-Lopez i Goldin-Meadow (2014) su pokazale da gestikulacija pomaže u transferu znanja na nove probleme, ali ne i samo izvođenje motorne radnje. Drugim riječima, gestikulacija dovodi do dubljeg i fleksibilnijeg učenja. Pozitivni utjecaj gestikulacije vjerojatno proizlazi iz mogućnosti da spacijaliziramo apstraktne ideje koje nisu inherentno spacijalne (Goldin-Meadow, 2014; Goldin-Meadow i Beilock, 2010).

1.1.8. Neuronske osnove utjelovljenja

Neuroznanstvena istraživanja također upućuju na mogućnost da je semantičko znanje povezano sa sustavima za percepciju i motoriku. U jednom od prvih istraživanja, Chao i Martin (1999) su pokazali da pasivno gledanje obojanih podražaja aktivira lingvalni girus, dok imenovanje boja aktivira susjedno, ali ipak odvojeno područje fuziformnog girusa. Drugim riječima, nije bilo preklapanja u neuronskoj aktivaciji između direktne percepcije i semantike. Simmons, Ramjee, Beauchamp, McRae, Martin i Barsalou (2007) su zaključili da do preklapanja nije došlo zato jer su Chao i Martin (1999) koristili pasivan zadatak gledanja boja koji ne angažira u dovoljnoj mjeri neuronske krugove za percepciju boje. Umjesto toga, Simmons i sur. (2007) se primijenili zahtijejniji zadatak razlikovanja boja. Pri tome su otkrili da se fuziformni girus aktivira i tijekom percepcije boja i tijekom doziva informacija o bojama iz pamćenja. Do sličnog rezultata došli su i Hsu, Kraemer, Oliver, Schlichting i Thompson-Schill (2011) koji su varirali težinu zadatka pamćenja. Oni su tražili od ispitanika da na osnovu pamćenja odrede je li boja jagode bliža boji maline ili boji rajčice (težak zadatak) ili da odrede je li boja jagode bliža boji višnje ili limuna (lagan zadatak). Hsu i sur.

(2011) su također pitali ispitanike da izvijeste o svojim sklonostima korištenju vizualizacije ili verbaliziranja tijekom rješavanja semantičkih zadataka. Zanimljivo je da je preklapanje neuronske aktivnosti između percepcije i pamćenja bilo veće kod onih ispitanika koji su skloni vizualiziranju informacija.

Preklapanje neuronske aktivnosti tijekom percepcije i semantičke obrade otkriveno je i kod drugih osjetnih modaliteta. Kiefer, Sim, Herrnberger, Grothe i Hoenig (2008) su pokazali da vidno prepoznavanje riječi koje označavaju objekte čija su relevantna obilježja zvukovi (telefon), aktivira neuronske krugove u lijevom gornjem i srednjem temporalnom girusu (pSTG/MTG) koji su aktivni tijekom percepcije zvukova. Štoviše, neuronska aktivnost u tim dijelovima korteksa se pojačava u funkciji relevantnosti akustičkih obilježja objekta, ali ne i u funkciji vizualnih ili motornih obilježja. U istraživanju koje su proveli Simmons, Martin i Barsalou (2005) od ispitanika se tražilo da odrede jesu li dvije prikazane slike identične ili nisu dok su pasivno ležali u fMRI skeneru. Na slikama je bila prezentirana hrana. Iako se od ispitanika nije tražilo da kategoriziraju podražaje niti da razmišljaju o njihovom okusu, već su samo morali riješiti zadatak na površnoj vidnoj razini, ipak se aktivirao i dio mozga zadužen za reprezentaciju okusa. Dakle, percepcija hrane aktivirala je kategorijalno znanje o hrani koje je opet proizvelo perceptivnu simulaciju okusa hrane u dijelu korteksa zaduženom za okuse.

Semantička obrada riječi koje označavaju radnje (dohvatiti, gurnuti) ili objekte kojima baratamo u svakodnevnom životu kao što različita oruđa (vilica, čekić) dovodi do aktiviranja motornih centara u korteksu (Pulvermüller, 2005; Pulvermüller i Fadiga, 2010). Ova aktivacija je specifična za reprezentaciju pojedinih dijelova tijela tako da riječ dohvatiti aktivira reprezentaciju ruke, riječ lizati aktivira reprezentaciju jezika a riječ šutnuti aktivira reprezentaciju noge. Slična aktivacija motornih područja javlja se i kod obrade akcijskih fraza i rečenica. Pri tome, važno je istaknuti da se motorna aktivacija tijekom semantičke obrade javlja samo za one radnje koje čovjek može sam izvesti, ali ne i za radnje koje nisu tipične za ljude kao što je lajanje ili mahanje repom. Neurofiziološka istraživanja pokazuju da se motorna aktivacija vezana uz semantičku obradu riječi javlja u rasponu od 100 do 250 ms nakon prezentacije podražaja što je u skladu s vremenskim okvirom u kojem se javlja neuronska aktivacija povezana s razumijevanjem riječi.

Zanimljivo obilježje neuronske aktivacije tijekom semantičke obrade otkrila je Thompson-Shill (2003). Ona je uočila da kortikalni centri koji se aktiviraju za vrijeme rješavanja semantičkih zadataka nisu identični centrima koji se aktiviraju tijekom percepcije

ili izvođenja radnji, ali su blizu njih i obično su pomaknuti naprijed. Na primjer, kod razumijevanja rečenica koje opisuju kretanje, aktivira se centar koji se nalazi ispred V5, ali se ne aktivira i sam V5 koji je aktivan za vrijeme percepcije pokreta (Wallentin, Lund, Ostergaard, Ostergaard i Roepstorff, 2005). Kod razumijevanja radnji aktivira se premotorni, ali ne i primarni motorni korteks (Willems, Hagoort i Casasanto, 2010; Willems, Toni, Hagoort i Casasanto, 2010). Ova pojava nazvana je anteriorni pomak. Prema nekim istraživačima, anteriorni pomak predstavlja apstrahiranje odnosno shematizaciju perceptivnih i motornih iskustava. Prema drugima, anteriorni pomak je argument protiv utjelovljenja jer pokazuje da neuronske aktivacije tijekom percepcije i semantičke obrade nisu izomorfne (Chatterjee, 2010; Rugg i Thompson-Schill, 2013). Također, u meta-analizi 120 studija koje su ispitivale semantičko pamćenje pokazalo se da nema velikog preklapanja između neuronske aktivacije tijekom rješavanja semantičkih i perceptivnih zadataka (Binder i sur., 2009). S druge strane, Martin (2009) naglašava da je zahtjev za potpunom ekvivalentnošću neuronskih struktura za percepciju, motoriku i semantiku apsurdan, jer bi to impliciralo nemogućnost razlikovanja percepcije od imaginacije i halucinacije. Prema Martinu (2009) i djelomično preklapanje između percepcije i semantike, kao i anteriorni efekt, predstavljaju potvrdu za utjelovljenje ako ga ne shvaćamo previše doslovno. Nadalje, u mnogim studijama semantike ne provjerava se direktno lokacija centara za percepciju i motoriku, nego se istraživači oslanjaju na prethodno objavljene radove drugih istraživača. Kada se direktno usporede neuronske aktivacije tijekom semantike i percepcije unutar iste studije, kao u istraživanju Simmonsa i sur. (2007), otkriva se barem djelomično preklapanje.

Neuropsihologijska ispitivanja ljudi s ozljedama glave mogu pružiti dodatne podatke o odnosu između percepcije, motorike i semantike. Istraživanja poremećaja specifičnih kategorija znanja upućuju na dvostruku disocijaciju između neuronskih krugova za pojmove koji označavaju živa bića i pojmove koji označavaju alate odnosno umjetno stvorene objekte. Pacijenti s ozljedama u području temporalnog i okcipitalnog korteksa pokazuju selektivni gubitak semantičkog znanja o živim bićima budući da su za njihovo razlikovanje bitna perceptivna obilježja (oblik, boja). Kod ovih pacijenata, znanje o alatima odnosno umjetnim objektima je ostalo sačuvano. S druge strane, postoje pacijenti s ozljedom frontalnog i motornog korteksa koji pokazuju selektivni deficit semantičkog znanja o alatima uz sačuvano znanje o živim bićima. Općenito, može se zaključiti da je znanje o kategorijama koje su prvenstveno definirane perceptivnim obilježjima smješteno blizu kortikalnih područja aktivnih tijekom percepcije, dok je znanje o kategorijama koje su prvenstveno definirane

motornim obilježjima (načinom rukovanja) smješteno blizu kortikalnih područja uključenih u izvođenje motornih radnji što ide indirektno u prilog hipotezi o utjelovljenju znanja (Martin, 2007; 2009).

Direktnija potvrda za utemeljenje znanja u sustavima specijaliziranim za percepciju i motoriku bilo bi otkriće da ozljede motornog ili senzornog korteksa dovode do semantičkih deficita. Međutim, istraživanja pacijenata s ozljedom motornog korteksa koji imaju teškoća u izvođenju radnji pokazuju da je njihovo semantičko znanje vezano uz radnje većim dijelom sačuvano (Negri i sur., 2007; Papeo i sur., 2010; Papeo i Rumiati, 2013). Pored poremećaja specifičnih kategorija postoji i semantička demencija koja označava progresivno propadanje općeg semantičkog pamćenja mjereno na zadacima imenovanja objekata i znanja o svojstvima objekata. Semantička demencija povezana je s atrofijom anteriornih temporalnih polova. Zbog toga se smatra da bi ta kortikalna struktura mogla biti sjedište simboličke reprezentacije znanja koja je neovisna o modalitetu (Patterson, Nestor i Rogers, 2007; Rogers i sur., 2004). Međutim, ne slažu se svi s ovom interpretacijom budući da neke studije pokazuju da je anteriorni temporalni režanj specijaliziran za socijalno znanje (Olson, Plotzker i Ezzyat, 2007; Ross i Olson, 2009).

Važan nedostatak istraživanja s funkcionalnim oslikavanjem mozga je da pruža samo uvid u korelaciju između mentalnog procesa i neuronske aktivacije, ali ne možemo zaključivati o kauzalnom odnosu između percepcije, motorike i semantike. Nadalje, tehnika fMRI-a zasniva se na mjerenju promjena u protoku krvi koji zahtjeva mnogo vremena zbog čega je dobiveni signal vremenski i prostorno neprecizan. Na kraju, rezultate gore opisanih istraživanja moguće je objasniti i u okviru teorije o amodalnoj reprezentaciji. Ako pretpostavimo da su amodalni simboli povezani sa svojom modalnom reprezentacijom te ju aktiviraju prilikom obrade informacija tada aktivacija senzornih i motornih područja može predstavljati samo artefakt važnijih obrada koje su smještene u drugim dijelovima mozga. Drugim riječima, aktivacija modalno-specifičnih kortikalnih područja tijekom semantičke obrade možda je samo usputna posljedica širenja neuronske aktivacije koja nastaje zbog činjenice da je mozak isprepleten brojnim sinaptičkim vezama (Caramazza, Anzellotti, Strnad i Lingnau, 2014; Mahon i Caramazza, 2008).

Kako bi doskočili opisanim prigovorima istraživači su primijenili tehniku transkranijalne magnetske stimulacije (TMS). To je jedina tehnika koja omogućava privremeno mijenjanje neuronske aktivnosti lokaliziranog kortikalnog područja. Tehnika se

sastoji u odašiljanju jednog ili niza magnetskih pulseva koji povećavaju šum u neuronskoj aktivnosti ciljanog kortikalnog područja. Ovaj postupak privremeno mijenja tekuću neuronsku aktivnost što se odražava u ponašanju odnosno u promjeni brzine ispitanikova odgovora ili u veličini evociranih motornih potencijala (Walsh i Pascual-Leone, 2003). Primjena TMS-a nad primarnim motornim korteksom (područje M1) pokazala je promjenu u brzini obrade riječi koje su povezane s pokretima ruke (uhvatiti) ili noge (šutnuti) ovisno o tome da li je magnetskim pulsom pogođeno motorno područje koje kontrolira kretanje ruke ili noge (Buccino i sur., 2005). Glenberg i sur. (2008) su primijenili TMS nad reprezentacijom ruke u M1 dok su ispitanici rješavali zadatak procjene semantičke plauzibilnosti. Ispitanicima su prezentirane rečenice koje opisuju fizički prijenos (*Dodao si papir Marku*), apstraktni prijenos (*Dodijelio si dužnost Ani*) ili ne opisuju nikakav prijenos (*Čitao si novine s Markom*). Rezultati su pokazali veće evocirane motorne potencijale kod rečenica koje su opisivale konkretni ili apstraktni prijenos nego kod kontrolnih rečenica koje nisu opisivale prijenos. Međutim, Papeo, Pascual-Leone i Carramazza (2013) su upozorili da je još prerano za zaključivati o kauzalnoj ulozi primarnog motornog korteksa u semantičkoj obradi budući da još nije utvrđena precizna kvantitativna veza između aktivacije motornog korteksa i izvedbe na semantičkim zadacima. Nadalje, opisani rezultati se mogu objasniti i vezom između motornog korteksa i amodalnog centra za semantiku pri čemu aktivacija motornog korteksa dovodi do aktivacije mreže pojmova koji su povezani s rukom ili nogom. Također su ukazali na činjenicu da se u navedenim TMS studijama pojavila facilitacija (ubrzanje izvedbe) dok se tipično očekuje interferencija (usporenje izvedbe) jer magnetski puls remeti neuronsku aktivnost. Opisani rezultati kao i različite moguće interpretacije istih upućuju na zaključak da je još prerano za donošenje odluke o ulozi utjelovljenja u semantičkom znanju samo na osnovi neuroznanstvenih metoda.

1.1.9. Simulacija, zrcalni sustav i razumijevanje drugih ljudi

Ljudi su društvena bića čije preživljavanje u velikoj mjeri ovisi o sposobnosti razumijevanja ponašanja, misli i osjećaja drugih ljudi. Prema teoriji simulacije, opažanje ponašanja i emocionalnih ekspresija drugih ljudi aktivira iste kognitivne i neuronske resurse koje koristimo kada izvodimo isto ponašanje (Gallese i Goldman, 1998; Gallese, Keysers i Rizzolatti, 2004; Keysers i Gazzola, 2006). Drugim riječima, simulacijom prilikom opažanja

ponašanja drugih ponovno proživljavamo slična mentalna stanja koja smo iskusili tijekom izvođenja tog ponašanja. Neuronska osnova socijalne simulacije mogla bi biti posebna vrsta vizuo-motornih neurona koji su nazvani zrcalni neuroni (*mirror neurons*). Oni su prvi put otkriveni u ventralnom premotornom korteksu ili području F5 majmuna, a kasnije i u inferiornom parijetalnom režnju (Rizzolatti i Craighero, 2004). Temeljno obilježje zrcalnih neurona je da se oni aktiviraju i u situaciji kada majmun sam izvodi određenu cilju usmjerenu radnju (npr. dohvaćanje) i kada opaža kako netko drugi izvodi tu istu radnju. Dakle, samo opažanje radnje dovodi do aktivacije istog dijela kortikalne neuronske mreže koji je aktivan pri izvođenju te radnje. Važno je napomenuti da se zrcalni neuroni ne aktiviraju prilikom izvođenja jednostavnih pokreta (savijanje prsta) nego samo na složene, svrhovite motorne radnje ili motorne činove kao što su dohvaćanje, trganje ili rukovanje (Rizzolatti i Sinigaglia, 2013). Zanimljivo je da je aktivnost zrcalnih neurona tijekom opažanja radnje značajno manja nego prilikom izvođenja radnje što znači da ovi neuroni implicitno razlikuju tko je agent koji izvodi radnju (ja ili drugi).

Neki zrcalni neuroni reagiraju i na zvukove koje proizvodi radnja. Primjerice, otkriveni su neuroni koji reagiraju na gledanje lomljenja kikirikija kao i na zvuk krckanja. Međutim, zrcalni neuroni ne reagiraju na netranzitivne radnje odnosno radnje koje nemaju neki cilj kao što je to pantomima. Kolika može biti složenost situacije na koju reagiraju zrcalni neuroni pokazuje istraživanje koje su proveli Umiltà i sur. (2001). Aktivnost zrcalnih neurona ispitivana je u dva uvjeta: u jednom je majmun mogao vidjeti čitavu radnju (npr. ruku koja izvodi pokret dohvaćanja nekog predmeta), a u drugom uvjetu bila je prikazana samo ruka koja izvodi pokret dohvaćanja, ali je cilj dohvaćanja odnosno predmet kojeg je ruka dohvatila bio skriven zato jer je stavljen u kutiju. Pri tome, majmun je mogao vidjeti da eksperimentator stavlja predmet u kutiju. Rezultati su pokazali da su isti zrcalni neuroni bili aktivni i u "skrivenom" uvjetu, odnosno u situaciji kada nije bio prikazan krajnji cilj tog pokreta.

Mnogobrojna istraživanja korištenjem različitih tehnika oslikavanja mozga pokazala su da i ljudi posjeduju zrcalni sustav koji im omogućuje preslikavanje percepcije ponašanja drugih ljudi na motorne reprezentacije u vlastitom mozgu (Caspers, Zilles, Laird i Eickhoff, 2010; Cattaneo, Sandrini i Schwarzbach, 2010; Chong i sur., 2008; Rizzolatti i Sinigaglia, 2010; Press, Weiskopf i Kilner, 2012). Odmah se postavila i hipoteza da zrcalni sustav kod ljudi ima mnogo širu ulogu i da je uključen u razumijevanje tjelesnih doživljaja i mentalnih stanja drugih ljudi kroz utjelovljenju simulaciju vlastitih doživljaja (Gallese i Goldman, 1998;

Gallese i sur., 2004; Keysers i Gazzola, 2006). Sukladno ovoj hipotezi, istraživanja su pokazala da se ista kortikalna struktura aktivira i kada doživljavamo određeni osjet ili emociju i kada percipiramo da ga doživljava druga osoba. Na primjer, kada ispitanik gleda film u kojem se nekoj osobi dodiruje noga predmetom, u ispitanikom mozgu aktivira se sekundarno somatosenzorno područje koje je aktivno i kada se ispitanikova noga dodiruje predmetom. Zanimljivo je da se isto područje ne aktivira u kontrolnoj situaciji kada ispitanik gleda film u kojem se predmet približava nozi osobe, ali ju ne dodiruje (Keysers i sur., 2004). Zadavanje bolnog podražaja (elektrošok) izaziva aktivaciju anteriornog cingulatnog korteksa i anteriorne insule. Međutim, ista područja aktiviraju se i kada osoba misli da je bolni podražaj zadan drugome ili direktno opaža nanošenje boli drugoj osobi (Singer i sur., 2004; Jackson, Meltzoff i Decety, 2005). Pri tome je veličina kortikalne aktivacije pozitivno povezana sa samoprocijenjenom empatijom ispitanika.

Anteriorna insula aktivira se i u situacijama kada doživljavamo gađenje. Wicker i sur. (2003) su pokazali da se anteriorna insula aktivira i prilikom gledanja filmova s glumcima koji pokazuju facijalne ekspresije gađenja. U skladu s tim, neuropsihologijska istraživanja pokazuju da osoba koja je izgubila sposobnost doživljavanja gađenja također ima problema i s prepoznavanjem gađenja na licima drugih ljudi. Slična logika može se primijeniti i na složenije doživljaje. Schie, Mars, Coles i Bekkering (2004) su pokazali zašto je nama neugodno kada vidimo da su drugi ljudi napravili grešku. Koristeći oslikavanje mozga utvrdili su da se tijekom opažanja situacije u kojoj druga osoba izvodi neki zadatak, i pri tome napravi grešku, aktiviraju iste neuralne strukture kao i kada sami činimo pogrešku u izvođenju zadatka. Konkretnije, snimanje mozga pokazalo je pojačanu aktivnost anteriornog cingulatnog korteksa u obje situacije. Pri tome, treba spomenuti da je u prethodnim istraživanjima dobiveno da je aktivnost anteriornog cingulatnog korteksa povezana s osjećajem nelagode/neugode.

Teorija utjelovljene simulacije objašnjava kako kroz ponovno proživljavanje tjelesnih i emocionalnih stanja nastaje empatija, a da pritom svjesno ne ulažemo kognitivni napor kako bi razumjeli emocionalno stanje druge osobe. Simulacija nam daje iskustveni uvid u ono što doživljava druga osoba, popraćeno svim tjelesnim manifestacijama takvih stanja (Gallese, 2003; Iacoboni, 2009). Na primjer, teorija može objasniti zašto se naježimo kada gledamo film u kojem pauk prelazi preko ruke glumca. Nadalje, disfunkcije zrcalnog sustava mogle bi biti u podlozi poremećaja kao što je autizam (Iacoboni i Dapretto, 2006). Međutim, treba napomenuti da simulacija kao mehanizam socijalne percepcije ima i bitna ograničenja (Jacob

i Jeannerod, 2005; Saxe, 2005). Naime, ljudi imaju sklonost objašnjavati razloge za svrsishodne radnje drugih ljudi pripisujući im uvjerenja i želje. Drugim riječima, ljudi posjeduju skup pretpostavki o tome kako mentalna stanja uzrokuju ponašanje odnosno posjeduju teoriju uma (Fodor, 1992). Simulacijom ne možemo objasniti kako je moguće znati da druga osoba ima drugačije uvjerenje od nas o stanju stvari u svijetu i da to uvjerenje tjera osobu da se ponaša na određeni način. Na primjer, u zadatku lažnog uvjerenja, kreira se situacija u kojoj ispitanik ima priliku opažati promjene u okolini koje druga osoba nije vidjela. U takvoj situaciji ljudi znaju da druga osoba ima drugačije (lažno) uvjerenje o danoj okolini (Saxe, 2005). Potrebna su daljnja istraživanja kako bi se utvrdilo postoji li način da se teorija simulacije i teorija uma objedine u cjelovito objašnjenje socijalne percepcije (Keysers i Gazzola, 2007).

1.1.10. Kritike utjelovljenja

Brojni empirijski nalazi koji potkrepljuju osnovne pretpostavke utjelovljene spoznaje doveli su do hipoteze o radikalnom utjelovljenju prema kojoj u potpunosti treba odbaciti simboličku reprezentaciju znanja (Glenberg, Witt i Metcalfe, 2013). Umjesto toga, jedino direktna senzorno-motorna interakcija s okolinom pruža znanje potrebno za snalaženje. Međutim, postoje i istraživanja koja ukazuju na ograničenja utjelovljenja. Solomon i Barsalou (2004) su otkrili da ispitanici ne koriste uvijek perceptivnu simulaciju prilikom rješavanja zadatka verifikacije svojstava. Kada postoje uvjeti za to, ispitanici koriste asocijativnu snagu između pojmova i riječi koje označavaju njihova svojstva. Drugim riječima, ispitanici imaju na raspolaganju barem dva različita izvora informacija, a za koji će se odlučiti u konkretnom slučaju ovisi o karakteristikama zadatka. Markman i Brendl (2005) su pokazali da se efekt kompatibilnosti između akcije i rečenice javlja i s obzirom na simboličku reprezentaciju sebe u prostoru, a ne samo s obzirom na položaj vlastitog tijela. Oni su pokazali ispitanicima sliku hodnika u kojem je u sredini bilo prikazano ime ispitanika. Zatim su prezentirali riječi ispred ili iza imena ispitanika, a zadatak je bio povući ručicu prema sebi ili od sebe ovisno o tome da li se radi o pozitivnoj ili negativnoj riječi. Rezultati su pokazali da su ispitanici bili brži u povlačenju ručice prema svom imenu za pozitivne riječi bez obzira na to da li se radilo o pokretu privlačenja ručice prema sebi ili odvlačenja ručice od sebe. Iz toga su zaključili da

mora postojati simbolička reprezentacija koja posreduje između jezične obrade i motorne izvedbe i stvara opisani efekt.

Maglio i Trope (2012) su pokazali da se efekt utjelovljenja javlja ovisno o tome kako ispitanici pristupaju rješavanju eksperimentalnog zadatka odnosno koji mod mišljenja (apstraktni ili konkretni) koriste. Jedna grupa ispitanika morala je razmišljati o tome zašto rješava zadatak (apstraktni mod) dok je druga grupa bila motivirana da razmišlja kako riješiti zadatak (konkretni mod). Rezultati su pokazali da se efekt utjelovljenja javio samo kod grupe kojoj je induciran konkretni mod mišljenja, ali ne i kod grupe koja je koristila apstraktni mod mišljenja. Neuroznanstvena istraživanja ukazuju na postojanje velikih interindividualnih razlika u aktivaciji senzornih i motornih područja tijekom pojmovne obrade (Hsu i sur., 2011; Rugg i Thompson-Schill, 2013). Također, preklapanje neuronske aktivacije između pojmovne i perceptivne obrade ovisi o težini zadatka. Kod laganih zadataka ne dolazi do preklapanja nego samo kod težih zadataka (Simmons i sur., 2007). Sva ova istraživanja ukazuju na činjenicu da perceptivna simulacija i utjelovljenje nisu jedini sveobuhvatni mehanizam reprezentacije znanja i razumijevanja već koegzistiraju s drugim oblicima reprezentacije kao što su amodalni simboli.

1.1.11. Apstraktni pojmovi

S teorijske strane identificirana su dva problema za utjelovljenu spoznaju. Prvi se odnosi na reprezentaciju apstraktnih pojmova odnosno pojmova koji nemaju direktno opipljiv referentni objekt. Primjer, takvih pojmova su ljubav, prijateljstvo, pravo, jednakost ili uzročnost. Dok mehanizam perceptivne simulacije može s lakoćom objasniti razumijevanje konkretnih pojmova, ostaje nejasno kako se taj mehanizam može generalizirati na apstraktne pojmove. Barsalou (1999) je predložio da reprezentacija apstraktnih pojmova nastaje putem perceptivne simulacije događaja. Pri tome, selektivna pažnja odabire ključne aspekte događaja koji čine sadržaj apstraktnog pojma. Pored toga, apstraktni pojmovi mogu biti utemeljeni u perceptivnoj simulaciji internalnih stanja kao što su emocije, motivacija i vjerovanja. U skladu s tim, Kousta, Vigliocco, Vinson, Andrews i Del Campo (2011) su otkrili da apstraktni pojmovi imaju jače asocijativne veze s riječima koje opisuju emocionalna stanja nego konkretni pojmovi. Također, pokazali su da se prije usvajaju apstraktni pojmovi koji imaju jače asocijativne veze s afektivnim stanjima. Barsalou i Wiemer-Hastings (2005) su pokazali

da su introspektivne informacije bitne za reprezentaciju apstraktnih pojmova. Međutim, ostaje nejasno kako se reprezentiraju znanstveni, tehnički, matematički i drugi pojmovi koji nemaju direktne veze s internalnim stanjima.

Objašnjenje razumijevanja apstraktnih pojmova predložili su Lakoff i Johnson (1980) analizom metafora u svakodnevnoj komunikaciji. Prema njima, metafora nije samo poetsko sredstvo karakteristično za književnost nego temeljni kognitivni mehanizam putem kojeg se ostvaruje preslikavanje između izvorne (konkretna) domene i ciljne (apstraktna) domene. Izvorna domena je utemeljena u konkretnom iskustvu interakcije s okolinom i sastoji se od malog skupa pojmova koji označavaju prostorne odnose (gore-dolje, naprijed-natrag, blizu-daleko), fizičke ontološke pojave (entitet, spremnik) i osnovne doživljaje i radnje (kretanje, hranjenje). Ovi pojmovi ne zahtijevaju daljnju elaboraciju unutar pojmovnog sustava već su razumljivi sami po sebi. Ciljnu domenu čini struktura obilježja nekog apstraktnog pojma za koju pronalazimo sličnosti s izvornom domenom. Preslikavanje se ostvaruje putem pojmovne metafore koja sustavno povezuje dvije domene. Boroditsky (2000) ističe da se u podlozi metaforičkog preslikavanja nalazi mehanizam razumijevanja analogija. U tom smislu, cilj pojmovne metafore je pružiti relacijsku strukturu apstraktna domene putem analogije s konkretnom domenom. Na primjer, pojmova metafora IDEJE SU HRANA uspostavlja vezu između konkretnog iskustva da hranjenjem utažujemo glad i apstraktna intelektualna domene u kojoj usvajanje nove ideje može zadovoljiti naš intelektualni apetit. Pri tome, važno je napomenuti da analogije nose relacijsku strukturu između domena, ali ne i površna obilježja izvorne domene pa tako iz pojmovne metafore o idejama kao hrani nećemo izvući zaključak da ideje mogu dovesti do debljanja ili da su neke ideje posebno ukusne.

Empirijske potvrde za teoriju pojmova metafora pružila je Boroditsky (2000) koja je proučavala kako ljudi apstraktan pojam vremena preslikavaju na konkretnu domenu prostora. U engleskom jeziku, vrijeme odnosno raspoređivanje događaja u vremenu s obzirom na opažača može se razumjeti putem dvije prostorne metafore: kretanje ega i kretanje vremena (Lakoff i Johnson, 1980). Kretanje ega označava situaciju kada se sam opažač kreće kroz prostor pri čemu se budućnost nalazi ispred njega, a prošlost je iza. Kod metafore kretanja vremena, vrijeme se shvaća kao rijeka koja teče ili kao pokretna traka koja se kreće pored opažača. U tom slučaju, prostorni odnos je obrnut jer su prošli događaji ispred nas, a budući događaji slijede iza. U eksperimentu kojeg je provela Boroditsky (2000) ispitanicima su dane slike koje shematski prikazuju kretanje objekta i koje su popraćene rečenicom koja je trebala pripremiti ispitanike da razmišljaju ili u skladu s metaforom kretanja ega ili u skladu s

metaforom kretanja vremena. Nakon toga, ispitanici su trebali interpretirati dvosmisleni rečenicu kao što je: *Sastanak zakazan za iduću srijedu pomiče se za dva dana naprijed*. Kod metafore kretanja ega, naprijed znači kretanje od opažača prema točki u budućnosti pa bi ispitanici trebali odgovoriti da je sastanak zakazan za petak. Nasuprot tome, kod metafore kretanja vremena, naprijed znači točku bliže opažaču pa bi ispitanici trebali odgovoriti da je sastanak zakazan za ponedjeljak. Dobiveno je da su ispitanici interpretirali značenje rečenice u skladu s prethodno induciranom prostornom metaforom. Nadalje, Boroditsky i Ramscar (2002) su pokazali da ljudi nesvjesno mijenjaju način razmišljanja o vremenu ovisno o svom trenutnom položaju u prostoru. Oni su pitali studente koji stoje u redu u menzi i putnike koji čekaju ukrcaj na avion da interpretiraju istu dvosmisleni rečenicu kao u prethodnom istraživanju. Dobili su da su ispitanici koji su dalje odmakli u redu više skloni promatrati vrijeme kroz metaforu kretanja ega i da u značajno većem postotku odgovaraju da je sastanak u petak nego ispitanici koji su tek na početku reda.

Lakoff i Nunez (2000) su primijenili analizu pojmovnih metafora i na apstraktne matematičke pojmove. Na primjer, pokazali su kako se elementarne aritmetičke operacije zbrajanja i oduzimanja mogu preslikati na konkretno iskustvo konstrukcije objekta koji se sastoji od više dijelova. Pri tome, svaki dio predstavlja jedan broj, a rezultat primjene operacije je novi broj odnosno konstruirani objekt. Dakle, aritmetičke operacije su shvaćene kao aktivnosti kojima objekt sastavljamo u veće cjeline ili rastavljamo na manje dijelove po određenim pravilima. Nadalje, zbrajanje i oduzimanje mogu se razumjeti i kao kretanje duž linije gdje ishodište predstavlja nulu, a brojevi su točke na zamišljenoj trajektoriji koju ostavlja kretanje objekta. Pri tome, zbrajanje dva broja, $A + B$, je kretanje od točke A u smjeru suprotnom od ishodišta za duljinu puta koja odgovara udaljenosti točke B od ishodišta. Oduzimanje, $A - B$, je kretanje prema ishodištu od točke A za duljinu puta koja odgovara udaljenosti od točke B do ishodišta. Osim elementarne matematike, Nadalje, Lakoff i Nunez (2000) su pokazali da se istom metodom mogu analizirati i složeni pojmovi više matematike. Na primjer, pojam skupa se preslikava na konkretno iskustvo s kolekcijom objekata u zatvorenom prostoru kao što su kuglice u posudi. Pojam beskonačnosti može se povezati s iskustvom kontinuiranog ponavljanja iste radnje. Pojam derivacije u matematičkoj analizi može se preslikati na slikovne sheme kretanja i postupnog približavanja rubu. Čak se i aritmetičke operacije s kompleksnim brojevima mogu preslikati na konkretno iskustvo rotacije u prostoru.

1.1.12. Gramatika

Drugi problem za utjelovljenu spoznaju proizlazi iz činjenice da razumijevanje značenja pojedinih riječi nije dovoljno za razumijevanje značenja rečenica. Dio značenja nosi gramatika odnosno skup pravila prema kojima sastavljamo riječi u rečenice. Na primjer, prostorna informacija može se prenijeti prijedlozima (u, na, ispod, iza), dok različiti nastavci riječi (sufiksi) pružaju informaciju o padežima i glagolskim vremenima. Padeži omogućuju izricanje različitih odnosa između onoga što znači riječ i sadržaja rečenice. Glagolska vremena daju vremenski okvir radnje, stanja ili zbivanja opisanih u rečenici. Temeljno obilježje gramatike je da osigurava produktivnost jezika i misli. Produktivnost se odnosi na činjenicu da možemo proizvesti i razumjeti beskonačno mnogo različitih propozicija iako ih nikada prije nismo susreli. Drugim riječima, jezik zahvaljujući gramatici posjeduje kombinatornu strukturu koja omogućuje neograničeno prekrajanje propozicija korištenjem ograničenih sredstava (riječi i pravila gramatike). Produktivnost jezika proizlazi iz njegove kompozicionalnosti, rekurzivnosti i razlikovanja pojedinačnog od općeg (Fodor i Pylyshyn, 1988; Pinker, 1997).

Kompozicionalnost je svojstvo jezika da se određena reprezentacija može izgraditi iz dijelova koji svaki za sebe imaju određeno značenje, a značenje cjeline proizlazi iz značenja dijelova i načina na koji su povezani u cjelinu. Na primjer rečenica *Dijete je pojelo puža* proizlazi iz značenja riječi *dijete*, *jesti* i *puž* i lako možemo shvatiti značenje te rečenice iako je možda nikad prije nismo čuli ili vidjeli. Drugim riječima, primjenjujući pravila sintakse možemo interpretirati značenje beskonačno velikog broja rečenica koje nikada prije nismo susreli. Rekurzija označava sposobnost uključivanja jedne rečenice unutar druge. Na primjer, rečenica *Dijete je pojelo puža* može se uključiti u širu rečenicu kao *Otac je vidio da je dijete pojelo puža*, a ova se rečenica može uključiti u još veću rečenicu tipa *Majka zna da je otac vidio da je dijete pojelo puža* i tako u beskonačnost. Rekurzija nam omogućava da stvaramo hijerarhijske strukture značenja uključivanjem pojedinih rečenica u šire cjeline. Kvantifikacija ili vezivanje za varijablu proizlazi iz činjenice da se informacija o nekom entitetu može na različite načine povezati sa drugim dijelovima rečenice. Na primjer, nije svejedno da li želimo reći da je određeno dijete u određenom trenutku pojelo puža ili da to dijete voli jesti puževe općenito ili da sva djeca općenito vole jesti puževe. U logici se koriste kvantifikatori i varijable kako bi se mogle praviti razlike između spomenutih ideja. Varijabla je simbol koji označava isti entitet u različitim propozicijama i najčešće se označava sa *x*, *y* i sl.

Kvantifikator je simbol koji označava izjavu tipa “postoji x za koji vrijedi ...” ili “za svaki x vrijedi ...”. Sva opisana obilježja lako se mogu implementirati u okviru amodalne reprezentacije znanja što joj daje velike mogućnosti u objašnjavanju i modeliranju ljudske spoznaje (Fodor i Pylyshyn, 1988; Pinker, 1997).

Barsalou (1999; 2003) je pokušao pokazati kako perceptivna simulacija može biti produktivna. On smatra da se perceptivna simulacija često pogrešno promatra kroz analogiju s video ili audio trakom na kojoj pohranjujemo svoja senzorno-motorna iskustva i po želji ih možemo ponovno odvrtjeti, ali ne možemo iskoračiti dalje od onog što je već snimljeno. Suprotno tome, perceptivnu simulaciju treba promatrati kao proces obrnut od procesa kreiranja perceptivnog simbola. Nastanak perceptivnog simbola obilježen je shematizacijom i odbacivanjem nepotrebnih perceptivnih detalja. S druge strane, simulacija znači ponovno dodavanje perceptivnih detalja na osnovnu shemu. Na primjer, kada želimo reprezentirati pojam KVADRAT ključno perceptivno obilježje koje se aktivira je oblik. S druge strane, boja ili veličina nisu bitne za simulaciju ovog pojma pa one ni nisu aktivirane. Međutim, kada želimo reprezentirati pojam VELIKI ŽUTI KVADRAT i boja i veličina postaju relevantne te se pažnja usmjerava i na ova obilježja. Dakle, u sustavu za percepciju boja aktivira se reprezentacija žute boje, a u sustavu za percepciju veličine aktivira se reprezentacija velikog objekta koji se sa simulacijom oblika kombinira u složeniju simulaciju novog pojma. Na isti način moguće je reprezentirati pojmove koje nikada prije nismo vidjeli, kao i pojmove koji ne postoje - na primjer ZLATNO BRDO. Ključno obilježje ovog procesa je da pažnja odabire mali podskup od svih mogućih perceptivnih reprezentacija koje će se u određenom trenutku aktivirati i integrirati u simulaciju. Međutim, Barsalou (1999; 2003) nije objasnio koji mehanizmi upravljaju usmjeravanjem pažnje tj. nije precizirao je li i pažnja na neki način utemeljena ili pažnjom upravljaju produkcijska (dakle amodalna) pravila. Drugim riječima, i dalje ostaje neriješeno pitanje mogu li se i kako gramatička pravila utemeljiti u percepciji i motorici.

1.1.13. Kontinuum utjelovljenja

Rezultati opisani u prethodnim poglavljima upućuju na zaključak da postoje brojni empirijski nalazi koji idu u prilog utjelovljenju kao specifičnom obliku reprezentacije znanja, ali postoje i istraživanja u kojima se ne javlja očekivani efekt utjelovljenja. Isto tako, postoje

važni teorijski argumenti za utjelovljenje (utemeljenje simbola, zaobilaženje problema transdukcije), ali postoje i argumenti protiv (apstraktni pojmovi, gramatika). Stoga Meteyard, Cuadrado, Bahrami i Vigliocco (2012) predlažu da utjelovljenje ne treba promatrati kao jedinstveni eksplanatorni mehanizam već je moguće razlikovati nekoliko pristupa koji se mogu posložiti uzduž jedne dimenzije koju su nazvali kontinuum utjelovljenja. Na tom kontinuumu moguće je razdvojiti barem četiri teorijske pozicije koje se razlikuju s obzirom na funkciju koju pridaju utjelovljenju u kognitivnom funkcioniranju:

1. Potpuno bez utjelovljenja
2. Sekundarno utjelovljenje
3. Slabo utjelovljenje
4. Jako utjelovljenje

Svaka od ovih teorijskih pozicija razlikuje se s obzirom na semantički sadržaj odnosno reprezentacijski format semantičkog pamćenja, neuronsku arhitekturu koju predlaže, i objašnjenje interakcija između pojmovnog znanja i percepcije i motorike.

1. Pristup bez utjelovljenja ekvivalentan je klasičnom pristupu reprezentaciji znanja koja je opisana u prvom poglavlju. Dakle, znanje je pohranjeno u odvojenom modulu u obliku semantičke mreže ili u obliku statističkih reprezentacija proizašlih iz analize zajedničkog pojavljivanja riječi kao što pretpostavljaju modeli kao što su HAL (Burgess i Lund, 1997) ili LSA (Landauer i Dumais, 1997). Iz toga proizlazi da neuronske strukture uključene u semantičko pamćenje nemaju nikakav prostorni ili vremenski dodir sa strukturama uključenim u percepciju i motoriku. U okviru ovog pristupa nije jednostavno objasniti zašto bi postojala interakcija između pojmova i percepcije. Striktno gledajući, direktna posljedica gore opisanih pretpostavki je da takva interakcija ne bi uopće trebala postojati. Međutim, kako bi se pomirile osnovne postavke pristupa bez utjelovljenja s empirijskim nalazima moguće je pretpostaviti postojanje indirektnih aktivacija ili uvesti apstraktnu reprezentaciju percepcije i motorike unutar postojeće simboličke reprezentacije. Međutim, Barsalou (1999; 2008) je

upozorio da je to samo ad hoc objašnjenje koje ne doprinosi znanstvenom napretku. Drugim riječima, uvijek je moguće naknadno doraditi teoriju kako bi objasnila podatke o interakciji iako sama teorija nije mogla predvidjeti postojanje takvih efekata prije nego što su otkriveni.

2. Sekundarno utjelovljenje također pretpostavlja postojanje zasebne amodalne reprezentacije, ali ta je reprezentacija povezana s modalnim sustavima za percepciju i motoriku. Ove veze postoje zbog toga što znanje proizlazi iz senzornih i motornih informacija odnosno semantička obrada zahtijeva doziv relevantnih senzornih i motornih informacija. Dakle, semantički sustav je nezavisan, ali povezan direktnim kortikalnim vezama s centrima za percepciju i motoriku. Interakcijski efekti objašnjavaju se pasivnim širenjem neuronske aktivacije od amodalnih simboličkih reprezentacija prema senzornim i motornim centrima putem opisanih kortikalnih veza. Iz navedenog proizlazi da semantička obrada aktivira senzorne i motorne sustave i ostavlja u njima tragove nebitne za samu semantiku (Mahon i Carramazza, 2008). U okviru ovog pristupa pretpostavlja se da je glavni modul za semantiku smješten u anteriornom temporalnom režnju (Patterson i sur., 2007; Rogers i sur., 2004).

3. Slabo utjelovljenje pretpostavlja da se semantičke reprezentacije barem djelomično konstituiraju iz senzorno-motornih informacija. Svaka senzorna ili motorna informacija koja se aktivira tijekom semantičke obrade ima reprezentacijsku ulogu odnosno postaje sadržaj semantike. Prema ovoj hipotezi, neuronske strukture uključene u semantiku djelomično se preklapaju s kortikalnim centrima za percepciju i motoriku. Preklapanje nastaje zato jer unutar centara za percepciju i motoriku dolazi do određene apstrakcije informacija odnosno ekstrahiranja perceptivnih i motornih obilježja koja su odmaknuta od neposredne percepcije i motorike. Drugim riječima, kodiranje obilježja stvara više holističku reprezentaciju koja je smještena blizu, ali ipak odvojena od struktura koje su uključene u direktno senzorno-motorno iskustvo. Interakcija između semantike i percepcije objašnjava se obostranim vezama između modalnih sustava i među-modalnih zona konvergencije koje sadrže amodalne reprezentacije. Pretpostavlja se medijacija kojom semantička obrada djeluje na percepciju i motoriku i obrnuto. Primjer ovog pristupa je teorija perceptivnih i apstraktnih semantičkih prostora prema kojoj je pojmovna struktura organizirana prema tipovima obilježja koja su definirana modalitetom pa tako postoje vidna, slušna, motorna i druga obilježja. Međutim, pored obilježja, postoji i zaseban semantički nivo koji nastaje povezivanjem obilježja u leksičko-

semantičke reprezentacije i koji nadilazi sama obilježja iako je u njima djelomično utemeljen (Vigliocco, Vinson, Lewis i Garrett, 2004).

4. Jako utjelovljenje pretpostavlja da se sva semantička obrada odvija direktno u senzornim i motornim centrima odnosno da je semantika potpuno ovisna o njima (Glenberg i Gallese, 2012). U ovom slučaju, interakcija između semantike i percepcije i motorike se objašnjava modulacijom unutar zajedničkog sustava, a ne medijacijom izvana. Na primjer, Gallese i Lakoff (2005) predlažu postojanje funkcionalnih grupa (*functional clusters*) unutar svakog modaliteta koje su zadužene za multimodalnu integraciju odnosno za povezivanje informacija s drugim modalitetima. Razumijevanje nastaje simulacijom radnji unutar funkcionalnih grupa. Meteyard i sur. (2012) u ovu grupu teorija uključuju i teoriju perceptivnih simboličkih sustava (Barsalou, 1999, 2003), model prožetog iskustvenika (Zwaan i Ross, 2004), indeksnu hipotezu (Glenberg i Robertson, 1999) i model funkcionalnih mreža riječi (Pulvermüller, 1999; 2001). Razlikovanje između slabog i jakog utjelovljenja slično je razlici između jednostavnog i radikalnog utjelovljenja koje je predložio Clark (1999). Jednostavno utjelovljenje pretpostavlja istovremeno postojanje i amodalnih i modalnih reprezentacija koje stupaju u interakciju i međusobno se oblikuju i nadopunjuju. S druge strane, radikalno utjelovljenje negira potrebu za amodalnom reprezentacijom, već smatra da je kompletno razumijevanje smješteno unutar sustava za specifične modalitete.

Meteyard i sur. (2012) zaključuju da prva teorijska pozicija nema empirijsku podršku. Naime, bez uključivanja ad hoc pretpostavki, klasični modeli reprezentacije znanja ne mogu objasniti utjecaj percepcije i motorike na semantičku obradu. Sekundarno utjelovljenje može objasniti osnovne demonstracijske efekte utjelovljenja, ali mu ne idu u prilog istraživanja koja upućuju na kauzalnu ulogu percepcije i motorike u semantičkoj obradi (Kiefer i Barsalou, 2013) kao i istraživanja s TMS-om (Buccino i sur., 2005; Glenberg i sur., 2008). S druge strane, čini se da je slabo utjelovljenje najviše usklađeno s podacima jer senzorno-motornim sustavima priznaje barem djelomičnu kauzalnu ulogu u semantici, a istovremeno objašnjava zašto se javlja anteriorni pomak u istraživanjima funkcionalnog oslikavanja mozga (Chatterjee, 2010; Thompson-Schill, 2003; Rugg i Thompson-Schill, 2013) te zašto disfunkcija percepcije i motorike ne mora nužno dovesti do teškog deficita u semantici (Negri i sur., 1997; Papeo i sur., 2010; Papeo i Rumiati, 2013). Upravo to su problemi za jako utjelovljenje koje pretpostavlja da semantička i perceptivna obrada nužno aktiviraju iste

kortikalne centre. Međutim, treba imati na umu da simulacija aktivira sustave za percepciju u manjoj mjeri nego sama percepcija pa je moguće da je ta aktivacija preslaba da bi bila detektirana funkcionalnim oslikavanjem mozga (Martin, 2007; 2009). Nadalje, u dosadašnjim istraživanjima uglavnom su korištene pojedinačne riječi kao podražaji. Moguće je da bi korištenje većih semantičkih cjelina kao što su rečenice ili tekstovi proizvelo snažniju perceptivnu simulaciju koja bi bila detektirana prilikom oslikavanja mozga. Nadalje, neke neuropsihologijske studije ipak sugeriraju postojanje problema sa semantikom nakon ozljede motornog korteksa (Kemmerer i sur., 2012). Meteyard i sur. (2012) zaključuju da zasad ne možemo sa sigurnošću odlučiti između 2., 3. i 4. teorijske pozicije te da će biti potrebna daljnja istraživanja kako bi se definitivno odgovorilo na pitanje je li utjelovljenje usputna pojava koja samo prati semantičku obradu ili igra bitnu ulogu u razumijevanju pojmova te je li ta uloga samostalna ili uključuje integraciju s amodalnom reprezentacijom.

1.1.14. Zaključno o utjelovljenju

Na osnovu pregleda literature može se zaključiti da postoji interakcija između percepcije, motorike, emocija i kognitivnih struktura i procesa uključenih u reprezentaciju znanja. Iz toga proizlazi da je ljudski um utjelovljen u istim onim procesima koji mu omogućuju uspješnu interakciju s okolinom, a efekti utjelovljenja se manifestiraju u jezičnom razumijevanju, učenju, pojmovnoj obradi i socijalnoj percepciji. Međutim, i dalje ostaje otvoreno pitanje je li i u kojoj mjeri je utjelovljenje relevantno za reprezentaciju znanja, odnosno da li suštinski doprinosi razumijevanju pojmova ili se radi o usputnoj pojavi koja nastaje zbog razloga koji su nebitni za samo razumijevanje kao što je nekontrolirano širenje aktivacije u neuronskoj mreži (Mahon i Caramazza, 2008). U tom smislu korisno je teorijsko razgraničenje između sekundarnog, slabog i jakog utjelovljenja (Meteyard i sur., 2012). Za sada nije moguće dati definitivan zaključak koja od navedenih teorijskih pozicija bolje objašnjava dane podatke te će biti potrebna daljnja kognitivna i neuroznanstvena istraživanja kako bi se potvrdila ili opovrgnula kauzalna veza između utjelovljenja i razumijevanja. Buduća istraživanja trebala bi također razjasniti granice utjelovljenja, odnosno utvrditi empirijska ograničenja kada se efekti percepcije i motorike javljaju, a kada izostaju i zašto. Također, potrebno je razviti računalne i neuro-računalne modele koji mogu podržati perceptivnu simulaciju i koji bi trebali razjasniti može li simulacija potpuno zamijeniti

klasične modele reprezentacije znanja kao što su semantičke mreže (Pezzulo i sur., 2011; 2013; Roy, 2005; Roy i Reiter, 2005) ili će biti potrebno napraviti kompromisna rješenja koja će uključivati i utjelovljenje i klasičnu simboličku reprezentaciju kako bi se došlo do cjelovite teorije o reprezentaciji znanja (Andrews, Vigliocco i Vinson, 2009; Domijan i Šetić, 2016; Louwerse, 2011; Perniss i Vigliocco, 2014; Pulvermüller, 2013; Riordan i Jones, 2011).

1.2. Numerička spoznaja

U suvremenom tehnološki razvijenom društvu, kompetentno baratanje brojevima od izuzetne je važnosti za uspješnu prilagodbu pojedinca. Istraživanja pokazuju da su osnovnoškolske matematičke vještine bolji prediktor kasnijeg akademskog postignuća od vještine čitanja ili socio-emocionalnih vještina (Duncan i sur., 2007). Nadalje, niska razina matematičkih sposobnosti povezana je s nižim indeksima životnog uspjeha (Parsons i Brynner, 2005). Na razini društva, napredak u matematičkoj kompetenciji povezan je s porastom bruto društvenog dohotka (Organizacija za ekonomsku suradnju i razvoj, 2010, str. 17) i porastom globalne ekonomske kompetitivnosti. Navedeni podaci ukazuju na potrebu temeljitog istraživanja kognitivnih i neuralnih osnova elementarnih numeričkih sposobnosti kao što su uspoređivanje brojeva po veličini, procjena brojnosti skupa ili mentalna aritmetika s jednoznamenkastim brojevima budući da one predstavljaju temelj na kojem se grade složenije matematičke vještine i znanje.

Istraživanja elementarnih numeričkih sposobnosti ukazuju na postojanje tri odvojena sustava za reprezentaciju i razumijevanje brojeva (Feigenson, Dehaene i Spelke, 2004; Gallistel i Gelman, 2005; Nieder i Dehaene, 2009; Piazza, 2010):

1. Sustav za egzaktne brojeve
2. Sustav za percepciju ili procjenu brojnosti (približne brojeve)
3. Sustav za automatsko prebrojavanje (subitizaciju)

Svaki od ovih sustava detaljno je proučavan kognitivnim i neuroznanstvenim metodama. Cilj ovog uvodnog dijela rada je opisati najvažnije spoznaje o funkcioniranju tih sustava i načinu kako oni doprinose razumijevanju brojeva. Pri tome, važno je napomenuti da se ovdje ne radi o proučavanju kognitivnih osnova same matematike, već o mnogo elementarnijim kognitivnim sposobnostima koje služe kao prekursor za usvajanje matematičkog znanja. Na primjer, velika pažnja u psihologijskim i neuroznanstvenim studijama posvećena je razumijevanju prirodnih brojeva, dok se o razumijevanju racionalnih, realnih i kompleksnih brojeva zna mnogo manje.

1.2.1. Sustav za egzaktne brojeve

Brojevi spadaju među najstarije poznate simbole u pisanoj povijesti budući da su sve civilizacije koje su razvile neki oblik bilježenja informacija ujedno razvile i sustav bilježenja brojeva. Marschak (1972) navodi da su kromanjonci prije 30.000 godina bilježili i pratili mjesečeve mijene putem urezivanja nizova oznaka na kostima. U Mezopotamiji i starom Egiptu razvijena je cijela društvena klasa pisara koji su najčešće bilježili koliko čega ima odnosno vodili su neku vrstu jednostavnog računovodstva. Najstariji poznati matematički dokumenti zapravo su bile upute mladim pisarima kako da nauče svoju vještinu (Gouvêa, 2008). Različite kulture razvile su različite brojevnne sustave za bilježenje brojeva i njihovo tumačenje. Na primjer, Sumerani su razvili seksagezimalni sustav zasnovan na bazi 60. Oni su imali zasebne simbole za brojeve od 1 do 59, a za prikaz brojeva većih od 59 koristili su opet simbole od 1 do 59, ali s promijenjenom pozicijom u zapisu. Drugim riječima, razvili su položajni brojevi sustav u kojem položaj znamenke u zapisu određuje njenu veličinu pa tako jedna brojka označava broj šezdesetica, a druga brojka označava broj jedinica. Na primjer, u seksagezimalnom sustavu broj 2.20 zapravo označava broj 140 u decimalnom sustavu jer $2 \times 60 + 20 = 140$. Zanimljivo je da se ovaj sustav zadržao do danas u bilježenju vremena budući da koristimo konvenciju da se sat sastoji od 60 minuta, a minuta od 60 sekundi. Druge kulture koristile su vigezimalni sustav koji kao bazu uzima broj 20. Danas koristimo decimalni sustav zasnovan na broju 10 kojeg su razvili indijski matematičari vjerojatno prije 5. stoljeća nove ere, a koji je preko arapskih matematičara u srednjem vijeku stigao u Europu. Zanimljivo je da su indijski matematičari prvi u povijesti uveli simbol nula koji je označavao prazno mjesto u zapisu odnosno ništa (Gouvêa, 2008).

Ključno obilježje baratanja brojevima je njegova fleksibilnost budući da brojeve koristimo u različitim kontekstima. Wiese (2003a; 2003b) je identificirao tri načina na koji se brojevi primjenjuju za označavanje objekata: kardinalno, ordinalno i nominalno označavanje. Kod kardinalnog označavanja, broj služi za određivanje kardinaliteta odnosno veličine skupa objekata ("tri knjige"). Dakle, odgovara nam na pitanje: Koliko nečega ima? Kardinalno označavanje možemo povezati i s određenom mjernom jedinicom kao kod "tri metra" ili "tri sekunde" kako bismo odredili količinu. Kod ordinalnog označavanja, broj koristimo kako bismo odredili položaj jednog objekta unutar nekog uređenog niza ili rang poretka objekata ("treći razred", "naš atletičar je stigao treći na cilj"). Kod nominalnog označavanja, broj koristimo kao arbitrarni simbol koji nam služi za identificiranje pojedinog objekta ("autobus

broj tri"). Drugim riječima, broj nam služi za imenovanje objekta iako smo ga mogli nazvati i nekako drukčije (npr., "autobus Ivan ili Marija"). Iako nominalno označavanje ne doživljavamo kao pravo numeričko označavanje budući da broj u ovom slučaju ne referira na kardinalitet ili redni poredak, ono je zapravo uobičajeno u svakodnevnom životu. Telefonski brojevi, osobni identifikacijski brojevi, brojevi računa u bankama ili brojevi na dresovima sportaša primjeri su nominalnog označavanja.

Kod kardinalnog označavanja uspostavlja se obostrano jednoznačno preslikavanje (matematičkim rječnikom: bijekcija) između skupa brojeva i skupa objekata. Preslikavanje se ostvaruje procesom prebrojavanja. Svakom objektu u skupu dodjeljujemo jedan jedinstveni broj pri čemu brojevi moraju činiti uređeni niz. Dakle, uvijek moramo prebrojavati istim redoslijedom 1, 2, 3 itd. i moramo paziti da ne prebrojimo isti objekt dvaput. Na kraju prebrojavanja, kardinalitet skupa odgovara broju kojeg smo dodijelili zadnjem objektu u skupu (Wiese, 2003b). Na taj način utvrđujemo egzaktnu jednakost između broja i veličine skupa. Egzaktna jednakost preduvjet je za razumijevanje pojma egzaktnog broja kao oznake za sve skupove s istom veličinom (kardinalitetom). U tom smislu govorimo o egzaktnim brojevima ("na polici je dvanaest knjiga"), za razliku od aproksimacija odnosno procjena veličine skupa ("na polici je desetak knjiga") o kojoj će biti više riječi u poglavlju 2. Kod ordinalnog označavanja koristimo drugo svojstvo prebrojavanja, a to je stvaranje redoslijeda ili poretka. U ovom slučaju, svaki novi broj u nizu nastaje tako da se prethodnik uveća za jedan, a ova operacija je nazvana funkcija nasljednik. Dakle, broj dva je nasljednik broja jedan, broj tri nasljednik je broja dva itd. Ordinalno označavanje nastaje rekurzivnom primjenom funkcije nasljednik. Zanimljivo je da su i egzaktna jednakost i funkcija nasljednik korištene kao polazna osnova za formalno-matematičku definiciju prirodnog broja (Izard i sur., 2008).

1.2.1.1. Usporedba brojeva po veličini

Temeljno obilježje egzaktnih brojeva jest da su to diskretni simboli koji označavaju jasno odvojene veličine odnosno kardinalitete skupova. Zbog toga, usporedba brojeva po veličini ne bi trebala predstavljati problem za odrasle ispitanike jer se svaki broj referira na precizno određenu numeričku veličinu koju je lako razlikovati od ostalih. Međutim, istraživanja s mjerenjem vremena reakcije i točnosti prilikom usporedbe dva broja po veličini

otkrila su dva zanimljiva efekta koja se kose s ovom intuicijom (Moyer i Landauer, 1967; 1973; Parkman, 1971):

1. *Efekt numeričke udaljenosti* je pojava da se vrijeme reakcije i broj grešaka smanjuju u funkciji numeričke udaljenosti između brojeva koji se uspoređuju. Na primjer, ispitanici će brže i točnije odgovarati kada uspoređuju po veličini 3 i 8, nego kada uspoređuju 3 i 4.

2. *Efekt numeričke veličine* je pojava da se, za istu numeričku udaljenost, vrijeme reakcije i broj grešaka povećava u funkciji veličine brojeva. Na primjer, ispitanici će brže usporediti brojeve 3 i 5, nego 7 i 9, iako je numerička udaljenost između ovih parova brojeva identična.

Ovi efekti upućuju na zaključak da egzaktna jednakost i funkcija nasljednik nisu dovoljne za razumijevanje kognitivnih mehanizama koji se nalaze u podlozi razumijevanja značenja brojeva. Umjesto toga, čini se da se mentalna reprezentacija egzaktnog broja oslanja na analognu odnosno kontinuiranu veličinu te da položaj na internalnom kontinuumu predstavlja osnovu za reprezentaciju njegovog značenja (Restle, 1970). Međutim, postavlja se pitanje kakva je točno priroda analogne reprezentacije na koju se egzaktni brojevi preslikavaju odnosno kakvi neuralni mehanizmi mogu biti u podlozi ovakve reprezentacije. Predložene su dvije hipoteze: 1) brojevi se preslikavaju na reprezentaciju prostora tvoreći mentalnu numeričku liniju (Dehaene i Changeux, 1993) i 2) brojevi se preslikavaju na rezultat neuralne integracije diskretnih pulseva (Gallistel i Gelman, 1992; 2000).

1.2.1.2. SNARC efekt i mentalna numerička linija

Dehaene, Bossini i Giraux (1993) otkrili su da ispitanici brže reagiraju lijevom rukom kada im je prezentiran numerički mali broj (1 ili 2) u zadatku određivanja pariteta broja. S druge strane, ispitanici reagiraju brže desnom rukom kada je prezentiran numerički veći broj (8 ili 9). Ova pojava nazvana je SNARC efekt (spatial-numerical association of response codes). SNARC efekt se javlja usprkos tome što sam zadatak određivanja pariteta nema

nikakve veze s procjenom veličine broja budući da i parni i neparni brojevi mogu biti numerički mali i veliki. Zanimljivo je da dominantnost ruke ispitanika nije imala utjecaja na pojavu efekta kao niti to da li su ispitanici prekrížili ruke prilikom odgovaranja, što upućuje na zaključak da ovaj efekt ovisi o alocentričnom koordinatnom sustavu koji ishodište ima izvan nas, a ne o egocentričnom sustavu koji ima koordinate postavljene relativno s obzirom na ruke. Međutim, efekt je bio mnogo slabiji kod osoba koje čitaju s desna na lijevo. Na osnovu dobivenih rezultata, Dehaene i sur. (1993) su zaključili da brojeve mentalno povezujemo s prostorom tako da ih poredamo po numeričkoj veličini uzduž dimenzije lijevo-desno pri čemu su mali brojevi smješteni lijevo, a veći brojevi desno. Na taj način nastaje mentalna numerička linija koja se automatski aktivira uvijek kada percipiramo brojeve i koja nam omogućuje dohvaćanje značenja broja odnosno njegovu numeričku veličinu (kardinalitet) čak i onda kada je to irelevantno za zadatak.

Zanimljivo je da uz pretpostavku da je mentalna numerička linija logaritamska, a ne linearna možemo objasniti postojanje efekta numeričke veličine i udaljenosti. Logaritamska reprezentacija znači da je prostorni razmak između malih brojeva veći nego razmak između velikih brojeva, odnosno mentalna numerička linija je zgusnutija na desno nego na lijevo, te će ljudima biti teže razlikovati numerički veće brojeve od manjih. Iz ove činjenice proizlazi da razlikovanje brojeva slijedi Weberov zakon koji vrijedi za sve osjetne modalitete (Dehaene, 2003). Prema Weberovom zakonu, promjena u intenzitetu podražaja koja je potrebna da se izazove razlika u osjetu (diferencijalni limen) proporcionalna je intenzitetu referentnog podražaja. Na primjer, ako pretpostavimo da je Weberova konstanta za brojeve jednaka 2, to znači da će ljudi numeričku udaljenost između brojeva 1 i 2 doživljavati subjektivno jednako veliku kao i udaljenost između brojeva 2 i 4 ili 4 i 8 ili 8 i 16 budući da svi navedeni parovi imaju isti omjer. Na taj način nastaju efekt numeričke veličine i udaljenosti.

1.2.1.3. Analogni integrator

Drugačiji pristup reprezentaciji veličine broja predložili su Gallistel i Gelman (1992, 2000). Prema njima, analogna reprezentacija veličine zasniva se na analognom integratoru koji zbraja ulazne signale (neuralne pulseve). Ulazni signali dolaze od biološkog sata koji konstantno ritmično otkucava (pacemaker). Između sata i neuralnog integratora postoje vrata koja se otvaraju ili zatvaraju, ovisno o volji ispitanika. Kada se vrata zatvore, započinje proces

akumuliranja neuralne aktivnosti u integratoru koji nalikuje prebrojavanju jer se za svaki puls iz biološkog sata aktivnost integratora povećava za određenu razinu. Kada se proces prebrojavanja želi prekinuti ili završiti, vrata se privremeno otvaraju i prolaz impulsa do integratora je prekinut. Nakon toga, rezultat integracije može se učitati u radno pamćenje što omogućuje usporedbu među različitim veličinama. Proces neuralne integracije može se metaforički prikazati kao ulijevanje malih čašica vode u menzuru. Svaka čašica vode koja se ulije u menzuru povećava razinu vode u menzuri. Na ovaj način može se implementirati neverbalno prebrojavanje jer svaka dodana čašica je jedan objekt ili događaj iz skupa čija veličina se želi odrediti, a konačna razina vode odgovara veličini broja. Sličan model predložili su Meck i Church (1983) s ciljem objašnjenja percepcije vremenskih intervala.

Nadalje, različite razine vode odnosno različita stanja neuralnog integratora mogu se učenjem povezati s odgovarajućim simbolom za broj čime nastaje preslikavanje egzaktnih brojeva na analognu reprezentaciju. Ovaj model također može objasniti efekte numeričke veličine i udaljenosti uz pretpostavku da postoji neuralni šum ili u procesu integracije ili u procesu očitavanja trenutne veličine u radno pamćenje. Šum u neuralnom integratoru dovodi do toga da će pulsevi koji dolaze u različito vrijeme ostaviti nešto drugačiji trag na trenutno stanje integratora. Na primjer, pretpostavimo da svaki puls povećava aktivnost integratora za otprilike 1, ali da prvi puls povećava razinu za 0.95, drugi puls za 1.03, teći puls za 0.99 i itd. Na taj način, prebrojavanje skupa od 3 objekta dovest će do razine aktivacije integratora koja neće biti točno nego 3 nego broj blizu 3. Međutim, kada bi se prebrojavao skup od 9 objekata, krajnja vrijednost integratora bi u većoj mjeri odstupala od prave vrijednosti 9 jer se efekt šuma zbraja tokom integracije. Ovaj efekt povećavanja šuma u funkciji veličine naziva se skalarni varijabilitet. Posljedica djelovanja skalarnog varijabiliteta je da će ljudi teže razlikovati veće brojeve od manjih što će proizvesti efekt numeričke veličine i udaljenosti.

1.2.1.4. Brojevi i prostor

Kao što je vidljivo iz prethodna dva poglavlja, polazeći od različitih pretpostavki, mentalna numerička linija i analogni integrator mogu objasniti efekte numeričke veličine i udaljenosti. Pored toga, oba modela korištena su za objašnjenje velikog broja bihevioralnih nalaza o razumijevanja brojeva kod odraslih ljudi, djece i životinja. Međutim, bitna razlika je da mentalna numerička linija pretpostavlja postojanje veze između brojeva i prostora, a kao

posljedicu pretpostavlja i postojanje SNARC efekta što prema modelu analognog integratora nije potrebno. Stoga je važno pitanje koliko je SNARC efekt robustan te postoje li i drugi nalazi koji govore u prilog veze između brojeva i prostora.

Istraživanja pokazuju da kod SNARC efekta postoji veliki interindividualni varijabilitet. Procjenjuje se da se SNARC javlja kod 65 do 75% ispitanika. Kod nekih ljudi otkrivene su idiosinkratičke veze između brojeva i prostora koje uključuju zakrivljene odnose kao na brojčaniku sata (Hubbard, Piazza, Pinel i Dehaene, 2005). Nadalje, otkriveni su i drugi nenumerički zadaci koji također proizvode SNARC efekt. Na primjer, SNARC se javlja u zadatku u kojem se od ispitanika tražilo da procjene fonemski sadržaj riječi za brojeve (Fias, Brysbaert, Geypens i D'ydewalle, 1996). Štoviše, SNARC se javlja i kod zadataka u kojima su brojevi potpuno irelevantni za zadatak kao u zadatku razlikovanja orijentacija linija (Fias, Lauwereyns i Lammertyn, 2001).

Alternativno objašnjenje SNARC efekta koje ne zahtijeva mentalnu numeričku liniju predložili su Proctor i Cho (2006). Prema njihovoj teoriji o slaganju polariteta, ključna determinanta izvedbe u zadacima binarne klasifikacije je sukladnost polova na dimenzijama podražaja i odgovora. Pretpostavka teorije je da se vrijednosti na dimenzijama uključenima u zadatak preslikavaju na + i - polaritet. Pri tome, + pol obično dobiva ona vrijednost dimenzije koja je salijentnija. Na primjer, desno se preslikava na + dok se lijevo preslikava na - pol. Isto tako, veliko se preslikava na + dok se malo preslikava na - pol. Kada postoji sukladnost polova kao u situaciji desno-veliko i lijevo-malo, doći će do bržeg i točnijeg odgovora na zadatak u odnosu na situaciju kada sukladnost polova ne postoji, desno-malo i lijevo-veliko. Drugim riječima, SNARC efekt se može objasniti kao apstraktnija varijanta Simonovog efekta odnosno kao posljedica kompatibilnosti između podražaja i odgovora (Santens i Gevers, 2008). U skladu s tim, meta-analiza 46 istraživanja koja su ispitivala SNARC efekt pokazala je da se u 60% studija javlja kategorijalni SNARC efekt tj. efekt kod kojeg nema interakcije s numeričkom veličinom (Wood, Nuerk, Willmes i Fischer, 2008).

Iz prethodnog razmatranja proizlazi da SNARC efekt ne mora nužno biti posljedica aktiviranja mentalne numeričke linije. Stoga je važno utvrditi postoje li drugi nalazi koji bi išli u prilog postojanju takve reprezentacije. Budući da je reprezentacija prostora usko povezana s usmjeravanjem pažnje u vidnom polju, zanimljivo pitanje je da li brojevi mogu utjecati na usmjeravanje pažnje. Kada se na sredini ekrana na mjestu fiksacijske točke prikaže broj, dolazi do automatskog usmjeravanja pažnje lijevo ili desno od fiksacijske točke ovisno o

numeričkoj veličini broja (Fischer, Castel, Dodd i Pratt, 2003). Drugim riječima, mali brojevi usmjeravaju pažnju u lijevi dio vidnog polja, dok veliki brojevi usmjeravaju pažnju u desno. Nadalje, pristranosti kod usmjeravanja pažnje mogu se detektirati i u zadatku određivanja sredine linije (bisekcija linije). Ispitanici su vrlo točni u bisekciji ukoliko se linija sastoji od slova:

xxxxxxxxxxxxxxxxxxxxxxxx

S druge strane, ako se linija sastoji od riječi za brojeve, kao što je:

devetdevetdevetdevetdevet

ili

dvadvadvadvadvadvadva

ispitanici će pokazati sistematsku pristranost kod lociranja sredine linije (Calabria i Rossetti, 2005; Fischer, 2001). Naime, ako se linija sastoji od riječi devet ispitanici će locirati njenu sredinu desnije od njenog stvarnog položaja, dok će kod linije koja se sastoji od riječi dva locirati sredinu više ulijevo od njenog stvarnog položaja. Nadalje, položaj broja u vidnom polju utječe i na izvedbu u zadatku usporedbe brojeva u kojem se tipično javlja efekt numeričke udaljenosti. Kod brojeva koji su manji od standarda, ispitanici brže odgovaraju kada se broj prezentira u lijevo nego u desno vidno polje. S druge strane, za brojeve veće od standarda, ispitanici reagiraju brže kada je broj prezentiran u desno vidno polje u odnosu na lijevo (Dehaene, Dupoux i Mehler, 1990).

Dodatni argument za povezanost brojeva s prostorom daju neuropsihologijske studije pacijenata s jednostranim zanemarivanjem (hemi-spatial neglect). Nakon ozljede desnog parijetalnog režnja, pacijenti pokazuju zanemarivanje podražaja koji su prezentirani na kontralateralnoj (lijevoj) strani prostora. Kod ozljede lijevog parijetalnog režanja ne dolazi do

sličnog poremećaja. Na testu bisekcije linije pacijenti s jednostranim zanemarivanjem obično pokazuju pristranost ka desnoj strani odnosno ignoriraju lijevi dio linije. U dvije studije koje su proveli Zorzi, Prifits i Umiltà (2002) te Vuilleumier, Ortigue i Brugger (2004) od pacijenata s jednostranim zanemarivanjem traženo je da odrede broj koji se nalazi na sredini različitih numeričkih intervala. Na primjer, trebali su odrediti broj koji se nalazi na sredini intervala između 3 i 12. Zanimljivo je da su njihovi odgovori sistematski odstupali prema brojevima koji su veći od točnog odgovora. Drugim riječima, čini se kao da su zanemarili lijevi dio mentalne numeričke linije na isti način kako zanemaruju lijevi dio prostora iako sam zadatak nije uključivo nikakvu prostornu komponentu odnosno pacijenti su dobivali zadatke i davali odgovor verbalno. Zanimljivo je da kod vrlo malih linija, kao i kod malih numeričkih intervala, dolazi do efekta križanja odnosno promjene smjera pristranosti. Drugim riječima, pacijenti pokazuju sklonost bisekcije linije ulijevo od stvarne sredine kao i odabira broja koji je manji od točnog odgovora. Kada se kod zdravih ispitanika repetitivnim TMS-om izazove privremena lezija u angularnom girusu dolazi do problema s izvođenjem zadataka numeričke usporedbe kao i kod zadataka vidnog pretraživanja (Göbel, Walsh i Rushworth, 2001). Pri tome, lezija u lijevom angularnom girusu dovodi do problema s velikim brojevima, a lezija u desnom angularnom girusu do problema s malim brojevima. Ovo je u skladu s pretpostavljenom orijentacijom mentalne numeričke linije budući da je lijevi angularni girus povezan s motornom reakcijom desne strane tijela i obrnuto za desni angularni girus.

Tehnike oslikavanja mozga također upućuju na blisku vezu između brojeva i prostora. Naime, više fMRI studija je pokazalo aktivaciju intraparijetalnog sulkusa (IPS) u obje hemisfere prilikom rješavanja različitih numeričkih zadataka kao što su usporedba brojeva po veličini, računanje ili procjena brojnosti (Dehaene, Piazza, Pinel i Cohen, 2003). Od prije je poznato da je ovo područje mozga uključeno u reprezentaciju prostora i kontrolu pažnje (Colby i Goldberg, 1999). Međutim, treba imati na umu da fMRI ne daje dovoljno preciznu sliku neuronske aktivacije te je moguće da se reprezentacija brojeva nalazi blizu prostorne reprezentacije, ali da su one zapravo odvojene i nepovezane (Cohen Kadosh i Walsh, 2009). S druge strane, elektrofiziološka mjerenja u mozgu primata su pokazala da postoje neuroni osjetljivi za brojnost objekata u vidnom polju i pored frontalnog režnja ovakvi neuroni su otkriveni i u parijetalnom režnju (Nieder, 2005; Nieder i Dehaene, 2009). Štoviše, otkriveno je postojanje neurona koji pokazuju zajedničku osjetljivost za duljinu linija i za brojnost što bi predstavljalo direktniji dokaz za vezu između brojeva i prostora (Tudusciuc i Nieder, 2007). Međutim, i ovdje postoje ograničenja u interpretaciji budući da nije otkriven nikakav

prostorni raspored ovih neurona s obzirom na brojnost za koju su osjetljivi. Drugim riječima, nije otkriveno da su neuroni za male brojeve smješteni u desnoj hemisferi, a za velike brojeve u lijevoj što bi predstavljalo najdirektniju potvrdu za neuronsku osnovu SNARC efekta. Na kraju, možemo zaključiti da, iako sam SNARC efekt ne mora nužno biti posljedica aktivacije mentalne numeričke linije kako sugeriraju neke bihevioralne studije, postoje brojni drugi nalazi koji upućuju na zaključak da postoji veza između brojeva i prostora koju modeli numeričke obrade moraju uzeti u obzir (Hubbard i sur. 2005; Fias i Fischer, 2005).

1.2.1.5. Mentalna aritmetika

1.2.1.5.1. Efekt veličine problema

Iako nam se na prvi pogled čini da rezultat zbrajanja dva jednoznamenkasta broja dozivamo iz dugoročnog pamćenja automatski i bez vidljivog napora, istraživanja mjerenjem vremena i točnosti potrebnog da se pronađe odgovor na postavljeni aritmetički zadatak pokazuju da trebamo više vremena i da radimo više grešaka kada rješavamo zadatak kao što je $9 + 7 = ?$ nego $2 + 3 = ?$. Ova pojava nazvana je efekt veličine problema pri čemu se aritmetički problem definira kao mali ili lagan ako je zbroj brojeva manji ili jednak 10, odnosno kao velik ili težak ako je zbroj veći od 10 (Zbrodoff i Logan, 2005). Zanimljivo je da se isti efekt javlja kod sve četiri računske operacije: zbrajanja, oduzimanja, množenja i dijeljenja. Također, efekt se javlja kod djece koja tek uče aritmetičke operacije kao i kod odraslih, pri čemu je efekt 10 do 20 puta veći kod djece. Efekt se javlja i u zadatku produkcije kada ispitanik mora dati točno rješenje (npr., $4 \times 5 = ?$) i u zadatku verifikacije kada je prikazan i rezultat operacije a zadatak ispitanika je da odredi da li je taj rezultat točan ili ne (npr., $4 \times 5 = 21$).

Postoji više objašnjenja zašto se javlja efekt veličine problema. U početku je ova pojava povezivana s brojenjem. Osnovna ideja modela je da ispitanik posjeduje brojač kojeg resetira na 0 kada počinje rješavati zadatak, a zatim dodaje jedinice brojaču i to onoliko jedinica koliko odgovara brojevima koje treba zbrojiti (Groen i Parkman, 1972). Naravno, takav pristup je vrlo neefikasan te su predložene varijante modela u kojem ispitanik bira manji ili veći broj u zadatku kao osnovu za brojenje. Na primjer, u zadatku $9 + 5$, ispitanik može

kao osnovu za brojač uzeti broj 9, a zatim dodati brojaču pet jedinica kako bi došao do rješenja 14. Efekt veličine problema objašnjava se time da je broj jedinica koje treba dodati veći kod većih problema pa će i ukupno vrijeme za rješavanje biti duže. Međutim, problem s ovim objašnjenjem je da se efekt veličine problema ne javlja kod zadataka koji uključuju identične pribrojnike (npr., $2 + 2$, $7 + 7$). Takvi zadaci rješavaju se brže što ukazuje na ulogu pamćenja u mentalnoj aritmetici.

Prema modelu koji su predložili Aschcraft i Battaglia (1978) mentalna aritmetika ne ovisi o procesu brojenja ili računanja nego se aritmetičke činjenice dozivaju iz semantičkog pamćenja. Struktura aritmetičkog pamćenja ima oblik tablice u kojoj stupci predstavljaju jednog pribrojnika, a redci drugog pribrojnika aritmetičkog problema. Rješenje problema se nalazi na sjecištu odgovarajućeg retka i stupca. Pri tome, do rješenja se dolazi pretraživanjem tablice startajući od početne pozicije (0,0). Efekt veličine problema proizlazi iz činjenice da je za velike probleme potrebno evaluirati veću površinu tablice (veći broj sjecišta) prije nego što se dođe do rješenja. Štoviše, model može objasniti i empirijski nalaz da je vrijeme reakcije proporcionalno kvadratu sume pribrojnika. Nadalje, isti model može se generalizirati na množenje gdje je također uočen isti odnos vremena reakcije i kvadrata sume množenika i množitelja.

Drugačiji pristup semantičkom pamćenju predložili su nezavisno Siegler (1987; 1988) i Campbell (1991). Oni su pretpostavili da nije potrebno pretraživati semantičko pamćenje, već se ispitanici oslanjaju na proces direktnog pristupa aritmetičkim činjenicama pomoću znakova za doziv. Pri tome, svaki znak može biti povezan s više odgovora zbog čega dolazi do kompeticije ili inhibicije među različitim odgovorima. Drugim riječima, dolazi do interferencije koja će biti veća kada postoji više asocijativnih veza između znakova i odgovora. Nadalje, Siegler i Campbell pretpostavljaju da je interferencija kod malih problema manja nego kod velikih problema. Do toga dolazi zbog činjenice da se mali problemi prije usvajaju i njih se više uvježbava. To potvrđuje analiza udžbenika u kojima su mali problemi češće zastupljeni i nalaze se na početku, dok se veliki problemi uvode kasnije kad su mali problemi već uvježbani. Zbog toga su memorijske veze za male probleme jače i lakše se opiru interferenciji.

U novije vrijeme istraživači su posvetili veću pažnju strategijama koje ispitanici koriste prilikom rješavanja aritmetičkih zadataka. Siegler (1987; 1988) je prvi istraživao činjenicu da djeca koriste različite strategije pri rješavanju aritmetičkih problema. U jednom

istraživanju pokazao je da djeca od 4 do 5 godina starosti koriste doziv iz pamćenja u 64% slučajeva, dok u manjoj mjeri koriste brojenje na prste (15%) ili brojenje bez korištenja prstiju (8%) ili koriste prste da bi reprezentirali brojeve, ali pri tome nisu brojili (13%). Zanimljivo je da su kod doziva iz pamćenja djeca radila više pogrešaka nego kod brojenja prstima iako je ova strategija brža u odnosu na brojenje. Analiza vremena reakcije s obzirom na korištenu strategiju je pokazala da je efekt veličine problema mnogo veći kod brojenja nego kod doziva. Kasnija istraživanja na odraslim ispitanicima pokazala su češće oslanjanje na strategiju doziva kod malih problema dok se kod velikih problema češće koristi računanje (Campbell i Fugelsang, 2001; Hecht, 2002). Iz toga proizlazi da je efekt veličine problema posljedica odabira različitih strategija rješavanja zadataka, a ne karakteristika semantičkog pamćenja ili brojenja.

1.2.1.5.2. Efekt formata

Ispitanicima treba više vremena i rade više grešaka kada je aritmetički problem prikazan slovima ($TRI + PET = ?$) nego brojkama ($3 + 5 = ?$). Ovaj efekt formata najprije je istraživao u engleskom jeziku a kasnije je repliciran i u mnogim drugim jezicima kao što su francuski, nizozemski ili kineski (Campbell i Epps, 2005). Zanimljivo je da je ovaj efekt prilično velik budući da aritmetički problemi prikazani u atipičnom formatu riječima usporavaju računanje za oko 30 % i dovode do 30% više grešaka od problema prikazanih u klasičnom formatu s brojkama (Campbell, 1994). Važno pitanje je da li se efekt formata javlja na nivou računanja ili na nekom drugom nivou obrade informacija. Na primjer, moguće je da efekt nastaje zbog dodatnog vremena i napora potrebnog da se kodiraju riječi za brojeve u odnosu na brojke. Međutim, Noël i sur. (1997) su pokazali da postoji interakcija u vremenu reakcije između formata i vrste zadatka. Naime, oni su uspoređivali brzinu i točnost izvođenja zadatka množenja i zadatka uspoređivanja brojeva. Kod zadatka uspoređivanja, ispitanici su gledali dva uzorka točkica dvije sekunde, a nakon toga im je prikazan par brojki ili par riječi za brojeve. Zadatak ispitanika bio je odrediti da li je par brojki ili riječi za brojeve odgovarao prethodno prikazanoj brojnosti točkica. Pri tome su pretpostavili da zadatak usporedbe brojeva u sebi uključuje i proces kodiranja brojki i riječi za brojeve. Stoga su pretpostavili da će se efekt kodiranja očitovati kao glavni efekt varijable vrsta zadatka. Međutim, dobivena interakcija između formata i vrste zadatka, koja je pokazala da je gubitak u vremenu nastao

zbog formata s riječima oko 2.5 puta veći u zadatku množenja nego u zadatku usporedbe brojeva, ukazuje na zaključak da se efekt formata ne može svesti samo na vrijeme potrebno za kodiranje riječi za brojeve.

Drugo moguće objašnjenje je da efekt formata nastaje prilikom pripreme odgovora zbog aktiviranja fonološke petlje pri davanju odgovora riječima. U tom slučaju, fonološki kodovi mogu interferirati s govornom produkcijom. Međutim, Campbell i Fuglesang (2001) su pokazali da se efekt formata javlja i u zadatku verifikacije točnog odgovara gdje nije potrebno dati odgovor riječima. Također, pokazali su da postoji interakcija između formata u kojem je prikazan aritmetički problem i veličine problema. Naime, efekt formata mnogo je izraženiji kod velikih nego kod malih problema. Prema Campbellu (1994), interakcija s veličinom problema ukazuje na to da efekt formata nastaje u trenutku računanja, a ne prije ili poslije zato što je sam efekt veličine posljedica procesa nastalih tijekom računanja kao što je objašnjeno u prethodnom odlomku. Ovakav rezultat ima važne implikacije za modele numeričke spoznaje budući da ukazuje na to da proces računanja nije potpuno odvojen od kontekstualnih utjecaja kao što je format prikaza aritmetičkih operacija.

1.2.1.5.3. Efekt prostornog grupiranja

Iz elementarne aritmetike znamo da u problemima koji uključuju više članova i više različitih operacija, prednost imaju množenje i dijeljenje ispred zbrajanja i oduzimanja. Landy i Goldstone (2010) otkrili su zanimljiv efekt kod primjene pravila prednosti. Oni su ispitanicima davali da rješavaju aritmetičke probleme pri čemu su manipulirali s fizičkom udaljenošću aritmetičkih simbola i brojeva. Na primjer, zadaci su izgledali ovako:

$$3 + 2 \times 4$$

ili

$$3 + 2 \times 4$$

U prvom slučaju, napravljen je veći razmak između znaka + i brojki 3 i 2 zbog čega se brojevi 2 i 4 lakše percipiraju kao cjelina. Nasuprot tome, u drugom slučaju, napravljen je veći razmak brojki oko znaka \times zbog čega se perceptivno lakše grupiraju brojevi 3 i 2. Upravo zbog blizine brojki i aritmetičkog znaka, Landy i Goldstone (2010) su otkrili da ispitanici brže i s manje grešaka rješavaju gornji primjer zadatka u odnosu na donji. U donjem primjeru, perceptivno grupiranje brojki i znaka ometa primjenu apstraktnog pravila prednosti. Nadalje, pokazali su da ispitanici, kada naprave grešku, češće daju kao odgovor numerički veći rezultat od točnog kada su brojevi i znakovi više razmaknuti. Ovaj nalaz ukazuje na mogućnost da se i prilikom rješavanja aritmetičkih problema aktivira prostorna reprezentacija kao što je mentalna numerička linija. Zanimljivo je da su sličan efekt prostornog grupiranja prethodno otkrili i kod rješavanja algebarskih izraza odnosno izraza kao što su $a + b \times c + d = d + c \times b + a$ (Landy i Goldstone, 2007).

1.2.1.5.4. Operacijski moment

Pored efekta prostornog grupiranja, postoji efekt koji još direktnije ukazuje na vezu između aritmetičkih operacija i prostorne reprezentacije. Knops, Viarouge i Dehaene (2009) su pokazali da se kod zadataka zbrajanja češće javlja greška da ispitanici daju numerički veći odgovor od točnog, a rjeđe numerički manji odgovor. S druge strane, kod zadataka oduzimanja ispitanici češće daju numerički manji odgovor od točnog. Isti efekt javlja se i kod egzaktne aritmetike kao i kod aproksimativne, odnosno u zadacima u kojima ispitanici daju samo približno rješenje (McCrink, Dehaene i Dehaene-Lambertz, 2007). Objašnjenje ovog efekta povezano je s kretanjem duž mentalne numeričke linije. Naime, možemo pretpostaviti da se zadaci rješavaju tako da se najprije prvi broj postavi na mentalnu numeričku liniju, a zatim se napravi skok ili korak koji odgovara numeričkoj veličini drugog broja kako bi se došlo do pozicije na liniji koja odgovara traženom rezultatu. U slučaju zbrajanja, skok ili korak se radi prema desno, a u slučaju oduzimanja ulijevo. Međutim, kao i kod stvarnog kretanja, moguće je da kretanje ima svoju inerciju te ga je teško zaustaviti kad jednom krene. Dakle, moguće je da kod zbrajanja češće dolazi do prebačaja odnosno da se griješi na način da se daje odgovor koji je veći od točnog, a kod oduzimanja do podbačaja odnosno davanja odgovora koji je numerički još manji od točnog odgovora. Zbog toga je ovaj efekt i nazvan operacijski moment. Ovakvu interpretaciju operacijskog momenta podupire i funkcionalno

oslikavanje mozga koje je pokazalo da se tijekom rješavanja aritmetičkih zadataka aktivira dio parijetalnog režnja koji je inače zadužen za usmjeravanje pažnje i pokreta očiju (Knops i sur., 2009). Pri tome, aktivacija je bila sukladna pretpostavljenom kretanju na mentalnoj numeričkoj liniji. Drugim riječima, zadaci zbrajanja aktivirali su dio parijetalnog režnja koji kontrolira pokrete očiju s lijeva na desno. S druge strane, zadaci oduzimanja aktivirali su dio zadužen za kontrolu pokreta očiju s desna na lijevo.

1.2.2. Sustav za percepciju brojnosti (Osjet za brojeve)

Iako se matematička znanja stječu formalnim obrazovanjem u školi učenjem apstraktnih pravila, mnogobrojna istraživanja pokazuju kako neke elementarne numeričke sposobnosti nije potrebno učiti, već su prisutne i spremne za upotrebu od rođenja, i to ne samo kod čovjeka već i kod mnogih životinjskih vrsta. Analizirajući numeričke sposobnosti životinja kao i ljudske intuicije o brojevima, Tobias Dantzig (1954) formulirao je ideju o osjetu za brojeve (*number sense*) kao zasebnom sustavu za približnu procjenu brojnosti. Ovaj sustav ne ovisi o jeziku i omogućuje nam da uočimo da se nešto promijenilo kada se nekom skupu objekata doda ili oduzme jedan ili više elemenata. Ideju je dalje razradio Dehaene (2001; 2011) i potkrijepio ju je s brojnim istraživanjima. Sustav za procjenu brojnosti daje nam samo približnu informaciju o tome koliko elemenata ima u skupu, ali ne može odrediti precizno kardinalitet skupa.

1.2.2.1. Metodološki aspekti istraživanja procjene brojnosti kod životinja i predverbalne djece

Istraživanja numeričkih sposobnosti neverbalnih organizama kao što su životinje i dojenčad povezano je s brojnim metodološkim problemima (Dehaene, 2011). U povijesti je zabilježeno više slučajeva pogrešnih zaključaka o inteligenciji životinja, a najpoznatiji primjer je slučaj pametnog Hansa, konja za kojeg se smatralo da posjeduje sposobnost egzaktnog simboličkog računanja. Konj je odgovarao udarcima kopitom o pod pri čemu je broj udaraca odgovarao točnom rješenju aritmetičkog zadatka koji mu je postavljen. Međutim, kada su njegove sposobnosti testirane u strogo kontroliranim uvjetima pokazalo se da pametni Hans zapravo nema sposobnost za egzaktnu aritmetiku već da reagira na neverbalne znakove svog

vlasnika poput pojačanog klimanja glavom ili obrvama kada se približava točnom rješenju. Ovaj slučaj često se navodi u udžbenicima iz metodologije psihologijskih istraživanja kao primjer prebrzog donošenja zaključaka na osnovu nedovoljne kontrole svih relevantnih varijabli koje mogu utjecati na rezultat mjerenja ili opažanja (Shaughnessy, Zechmeister i Zechmeister, 2011). Stoga su istraživači posebno oprezni i vrlo kritični pri prihvaćanju zaključaka o numeričkim sposobnostima kod životinja. Moderna istraživanja sposobnosti predočavanja brojeva moraju dizajnirati podražaje tako da je broj objekata u skupu jedina invarijantna karakteristika podražaja kada se objekti zamijene, pod uvjetom da svojstvo količine ostane nepromijenjeno. Dakle, da bismo saznali mogu li životinje ili djeca apstraktno predočavati brojeve moramo pokazati da njihovo ponašanje ostaje jednako usprkos velikim promjenama u nenumeričkim karakteristikama objekata u skupu. Neke od promijenjenih karakteristika mogu biti u fizičkom izgledu, boji i obliku, može se varirati lokacija u prostoru kao i način prezentacije podražaj (simultano ili sukcesivno).

1.2.2.2. Procjena brojnosti kod životinja

Mechner (1958) je osmislio eksperimentalnu metodu za ispitivanje procjene brojnosti kod laboratorijskih miševa. Nakon privremene deprivacije hranom, miševе se stavlja u zatvorenu kutiju u kojoj se nalaze dvije tipke koje možemo označiti kao A i B. Tipka B povezana je s mehaničkim uređajem koji dostavlja malu količinu hrane u kutiju. Međutim, miš ne dobiva hranu odmah nakon pritiska tipke B. Umjesto toga, miš mora pritisnuti tipku A određeni broj puta prije nego pritisne tipku B kako bi dobio hranu. Ukoliko bi miš prerano pritisnuo tipku B bio bi kažnjen. Metodom pokušaja i pogrešaka, miševi su uspjeli naučiti da moraju pritisnuti tipku A n puta prije nego pritisnu tipku B. Pri tome je broj n varirao među miševima tako da su neki morali pritisnuti tipku A 4 puta, druga grupa je morala pritiskati tipku A 8 puta, treća grupa 12 puta, a četvrta grupa čak 16 puta. Sve su grupe nakon određenog perioda učenja uspijevale savladati zadatak. Zanimljivo je da broj pritisaka na tipku A nije uvijek bio precizan. Miševi su ponekad kad je trebalo odgovoriti s 8 pritisaka pritiskali i 9 ili 10 puta. Otkriveno je da je varijabilitet odgovaranja rastao s veličinom brojeva. Dakle, kada je ciljni broj bio 4 miševi bi odgovarali u rasponu od 3 do 7 pritisaka, ali kada je traženi broj bio 16 njihov odgovor je varirao unutar mnogo većeg intervala od 12 do

24 pritisaka. Drugim riječima, miševi su pokazivali iste efekte numeričke veličine i udaljenosti kao i ljudi.

U daljnjim istraživanjima, Mechner (1962) je pokazao da ovakvo ponašanje miševa ne može biti posljedica samo osjetljivosti na dužinu vremenskih intervala. Kada je varirao vrijeme deprivacije hranom pokazalo se da su miševi u situaciji kada su jako gladni mnogo brže pritiskali tipke, ali da je broj pritisaka ostao isti. Dakle, iako je ukupni vremenski interval prije dobivanja hrane varirao ovisno o stupnju gladi, miševi su pokazali sposobnost reprezentacije broja potrebnih pritisaka tipke. Štoviše, Church i Meck (1984) su pokazali da miševi mogu neovisno usmjeriti pažnju na broj događaja ili na trajanje događaja. Miševima su prezentirana dva auditorna niza. Jedan niz se sastojao od dva tona ukupnog trajanja od dvije sekunde. Drugi niz se sastojao od osam tonova koji su prezentirani u ukupnom trajanju od osam sekundi. Dakle, miševi su imali na raspolaganju broj zvukova u nizu ili ukupno trajanje niza kao znak za učenje. Kada bi čuli prvi niz miševi su morali pritisnuti tipku A, a kada bi čuli drugi niz morali su pritisnuti tipku B. U drugom dijelu eksperimenta, korišteni su novi zvučni nizovi koji su imali ili fiksnu ukupnu duljinu ili fiksni broj tonova. Kada je bila fiksna duljina niza, miševi su koristili broj tonova kako bi razlikovali nizove. S druge strane, kada je broj bio fiksna, koristili su ukupnu duljinu kao znak za razlikovanje nizova.

Važno pitanje je da li miševi u prethodnim istraživanjima doista stvaraju reprezentaciju broja kao apstraktnog svojstva koje je neovisno od fizikalnih karakteristika podražaja ili je njihovo ponašanje vezano uz osjetni modalitet iz kojeg dolazi podražaj. Da bi odgovorili na ovo pitanje Church i Meck (1984) su proveli eksperiment u kojem su miševima zadavane sekvence od dva ili četiri tona ili sekvence od dva ili četiri svjetlosna bljeska. Kada su prezentirana dva tona ili dva bljeska miševi su morali pritisnuti tipku A a kada su prezentirana četiri tona ili četiri bljeska morali su pritisnuti tipku B. Nakon što su naučili asociirati broj zvučnih ili svjetlosnih podražaja s određenom tipkom uslijedio je test u kojem su zvučni i svjetlosni signali kombinirani u jednom nizu. Kada je prezentiran jedan ton i jedan bljesak miševi su odgovarali pritiskom na tipku A. Kada su prezentirana dva tona i dva bljeska miševi su odgovarali pritiskom na tipku B iz čega proizlazi da miševi imaju sposobnost zbrajanja vidnih i slušnih događaja.

Životinje su također sposobne i za jednostavnu aritmetiku kao i za uspoređivanje brojeva po veličini. Rumbaugh, Savage-Rumbaugh i Hegel (1987) su kreirali situaciju u kojoj čimpanza mora birati između dvije ploče na kojima se nalaze komadići čokolade. Na jednoj

ploči se nalaze dvije hrpice čokolade pri čemu jedna hrpica ima 4 komadića a druga 3 komadića čokolade. Na drugoj ploči se također nalaze dvije hrpice čokolade, ali na jednoj hrpi je 5 komadića, a na drugoj je samo jedan komadić čokolade. Istraživanje je pokazalo da kada se čimpanzi da dovoljno vremena da prouči cijelu situaciju ona će uvijek birati onu ploču koja sadrži ukupno više komadića čokolade. Drugim riječima, čimpanza će izračunati da na jednoj ploči ukupno ima $3 + 4 = 7$ komadića, dok na drugoj ploči ima $5 + 1 = 6$ komadića i nakon toga odrediti da je 7 veće od 6 te da će tim izborom dobiti više čokolade. Naravno, i u ovom istraživanju čimpanze su povremeno radile greške. Kada je numerička udaljenost brojeva koje treba usporediti velika kao npr. usporedba 2 i 6 broj grešaka je bio mali. Međutim, kada je trebalo usporediti numerički bliske brojeve broj grešaka je bio mnogo veći. Također, broj grešaka je rastao u funkciji numeričke veličine u skladu s Weberovim zakonom o razlikovanju veličina. Drugim riječima, i kod približnih procjena brojnosti kod životinja javljaju se isti efekti numeričke udaljenost i numeričke veličine kao i kod egzaktnih usporedbi brojeva kod ljudi. Ovi efekti javljaju se i kod drugih vrsta kao što su miševi, golubi, delfini, a javljaju se i u drugim numeričkim zadacima iz čega proizlazi da se radi o općim zakonitostima koja upravljaju našim predodžbama o brojevima i koja nam pružaju uvid u moguće mehanizme reprezentacije brojeva (Dehaene, 2011).

1.2.2.3. Procjena brojnosti kod predverbalne djece

Procjena brojnosti kod djece ispituje se različitim varijantama tehnike habituacije. Osnovna ideja je da se dijete izloži podražaju (skupu točkica) određene brojnosti na koji se dijete navikne (habituiru). Nakon toga, djetetu se prikaže novi podražaj s drugačijom brojnošću. Ako dijete pokaže interes za novi podražaj, možemo zaključiti da je dijete zapazilo razliku između dva podražaja odnosno da može razlikovati dva broja (Goswami, 2008). Cooper (1984) je koristeći habituaciju pokazao da dojenčad starosti 14 mjeseci može razlikovati relacije "veće od" i "manje od", dok dojenčad starosti 10 mjeseci može samo razlikovati relacije "jednako" od "nije jednako".

Najpoznatije istraživanje numeričkih sposobnosti petomjesečne dojenčadi provela je Wynn (1992) mjereći njihovo vrijeme gledanja određene situacije. Kreirala je posebnu paradigmu u kojoj se pred dijete postavi mala pozornica. Kada dijete usmjeri pažnju na pozornicu, eksperimentator postavi lutku na pozornicu. Zatim se podigne zaslon koji zaklanja

pogled na lutku. Nakon toga, dijete vidi da eksperimentator dovodi novu lutku iza zaslona. Međutim, kada se zaslon spusti, kreirane su dvije situacije: 1) dijete vidi dvije lutke (moguća situacija) ili 2) dijete vidi jednu lutku (nemoguća situacija). Djeca su više vremena gledala nemoguću situaciju tj. njihova očekivanja o broju lutaka iza zaslona nisu odgovarala onome što vide. Isti rezultat je dobiven i kod oduzimanja kada su na početku bile postavljene dvije lutke. Nakon dizanja zaslona dijete je vidjelo da jedna lutka odlazi. Na osnovu tog rezultata, Wynn (1992) je zaključila da djeca mogu spontano izračunati rezultat zbrajanja i oduzimanja.

Temeljni problem s istraživanjem procjene brojnosti je što je svaka promjena broja objekata povezana s promjenom fizičkih karakteristika podražaja kao što je ukupna veličina podražaja. Kasnija istraživanja pokušala su pažljivo kontrolirati utjecaj perceptivnih varijabli. Xu i Spelke (2000) su pokazale da djeca od 6 mjeseci starosti mogu razlikovati 8 od 16, ali ne mogu razlikovati 8 od 12 objekata. Također, mogu razlikovati 4 od 8 objekata, ali ne mogu razlikovati 2 od 4 objekta (Xu, 2003). Iz ovih istraživanja proizlazi da su djeca sposobna razlikovati brojeve kada je omjer brojnosti 1:2, dok ne mogu razlikovati manje omjere kao što je 3:4 što je sukladno Weberovom zakonu. Iznimka od ovog pravila je nemogućnost razlikovanja brojnost 2 i 4, a Xu, Spelke i Goddard (2005) su pokazale da djeca ne mogu razlikovati 1 od 2 objekta dok je s druge strane razlikovanje između 16 i 32 objekata moguće iako se u oba slučaja radi o istom omjeru 1:2. Odstupanje od Weberovog zakona se pripisuje djelovanju zasebnog sustava za male egzaktno brojeve koji je opisan u poglavlju 3. Drugim riječima, djeca koriste osjet za brojeve odnosno analognu reprezentaciju veličina kada percipiraju veću brojnost, dok za manju brojnost imaju na raspolaganju sustav za subitizaciju (Goswami, 2008).

Istraživanja su pokazala da i starija djeca koriste analognu reprezentaciju veličina kada procjenjuju brojnost objekata u vidnom polju. Huntley-Fenner i Cannon (2000) su tražile od djece u dobi od 3 do 5 godina da usporede dva stupca crnih kvadrata i da odrede koji stupac ima više kvadrata. Broj kvadrata u oba stupcu mogao je varirati između 1 i 15. Omjer broja kvadrata u stupcima mogao je biti 1:1, 1:2 ili 2:3. Kada je omjer bio 1:2, usporedba je bila između 1 i 2, 2 i 4, 3 i 6, 4 i 8 te 5 i 10 kvadrata. Kod omjera 2:3, usporedba je bila između 2 i 3, 4 i 6, 6 i 9, 8 i 12, te 10 i 15 kvadrata. Rezultati su pokazali da je točnost odgovora bila 81% kada je omjer bio 1:2, dok je kod omjera 2:3 izvođenje bilo na razini pogađanja (53%) sukladno Weberovom zakonu. Pri tome, Huntely-Fenner i Cannon su bilježile da li djeca koriste prebrojavanje tijekom usporedbe. Pokazalo se da prebrojavanje nema bitnog utjecaja na izvedbu jer je ovu strategiju koristilo samo manji postotak djece od ukupnog uzorka i nije

bilo razlike u uspješnosti između djece koja su koristila prebrojavanje i djece koja nisu. U sličnom istraživanju, Huntley-Fenner (2001) je pokazao da se i djeca od 5 do 7 godina oslanjaju na analognu reprezentaciju. Djeca su procjenjivala brojnost skupa crnih kvadrata tako da pokažu odgovarajući broj na numeričkoj liniji od 1 do 20. Kvadrati su prikazivani tahitoskopski (vrijeme prezentacije 250 ms) i nakon toga maskirani kako bi se spriječilo prebrojavanje. Rezultati su pokazali da varijabilitet odgovora raste u funkciji brojnosti kvadrata, što je također u skladu s Weberovim zakonom. Zanimljivo je da točnost izvođenja zadatka nije rasla u funkciji rednog broja pokušaja što pokazuje da se rezultat ne može objasniti djelovanjem perceptivnog učenja.

Međutim, potencijalni problem s prethodnim istraživanjima je da nisu kontrolirala perceptivne varijable kao što je ukupna površina podražaja. Kako bi odgovorili na ove kritike, Barth i sur. (2005) su tražili od petogodišnjaka da uspoređuju dva skupa točkica. Skupovi točkica su kreirani tako da osim njihove brojnosti varira i veličina svake točkice i ukupna površina koje točkice zauzimaju. Međutim, izvedba na zadatku nije ovisila o perceptivnim varijablama nego samo o brojnosti. Nadalje, Jordan i Brannon (2006) su direktno usporedile izvedbu šestogodišnjaka s izvedbom rhesus majmuna na istom zadatku numeričke sličnosti. U ovom zadatku od ispitanika se traži da ciljnu brojnost uspoređi s dva skupa točkica i odredi kojem je skupu numerički bliži. Na primjer, ispitanici su morali procijeniti je li skup od 4 točkice sličniji skupu od 2 ili 8 točkica. I u ovom zadatku izvedba je bila pod utjecajem Weberovog zakona, ali posebno zanimljivo je bilo to da su psihofizičke funkcije dobivene s djecom bile skoro identične kao i one dobivene s majmunima što daje dodatnu potvrdu zaključku da je osjet za brojeve specijaliziran, evolucijom oblikovan sustav kojeg dijelimo s drugim vrstama (Dehaene, 2011).

1.2.2.4. Neuronske osnove osjeta za brojeve

Neuronski krugovi vezani uz reprezentaciju brojnosti smješteni su u parijetalnom režnju (Dehaene, Molko, Cohen i Wilson, 2004). Analizirajući rezultate brojnih studija koje su koristile tehniku funkcionalnog oslikavanja mozga, Dehaene, Piazza, Pinel i Cohen (2003) identificirali su horizontalni segment intraparijetalnog sulkusa (HIPS) kao strukturu koja se aktivira u svim zadacima u kojima se manipulira brojevima kao što su mentalna aritmetika, usporedba brojeva po veličini, određivanje pariteta i slično. Pri tome, aktivacija HIPS-a

postaje veća što zadatak zahtijeva dublju numeričku obradu. Nadalje, jačina aktivacije HIPS-a obrnuto je proporcionalna numeričkoj udaljenosti među brojevima u zadacima usporedbe brojeva po veličini. Drugim riječima, aktivnost ovog područja je veća kada su brojevi bliži kao kod usporedbe 5-6 nasuprot 5-9 (Piazza i sur., 2004).

Zanimljivo je da se HIPS aktivira neovisno o formatu u kojem se brojevi prezentirani (kao brojke, riječi za brojeve ili kao skupovi točkica). Iz toga se može zaključiti da HIPS sadrži amodalnu ili apstraktnu reprezentaciju brojeva koja ne ovisi o formatu numeričkog podražaja (Piazza, Pinel, Le Bihan i Dehaene, 2007). Međutim, ne slažu se svi s ovom interpretacijom budući da fMRI signal predstavlja aktivnost velikog broja neurona te je lako moguće da se aktivnost odvojenih neuronskih krugova stopi odnosno uprosječi unutar istog volumetrijskog elementa tj. voxela (Cohen Kadosh i Walsh, 2009). U skladu s tim, novije istraživanje pokazuje da brojke i skupovi točkica aktiviraju ipak različita područja unutar parijetalnog režnja (Holloway, Price i Ansari, 2010).

1.2.2.5. Neuropsihologija

Najpoznatiji slučaj stečene diskalkulije je pacijentica CG koja je potpuno izgubila sposobnost baratanja brojevima većim od 4 nakon ozljede dijela lijevog parijetalnog režnja (Cipolotti, Butterworth i Denes, 1991). Ona nije mogla prebrojavati skupove veće od 4 objekta, nije mogla računati s brojevima većim od 4 i nije mogla prepoznati brojeve veće od 4. U svakodnevnom životu je imala velike probleme jer nije mogla obavljati kupnju odnosno plaćati novcem, koristiti telefon ili gradski prijevoz. Međutim, znanje o brojevima do 4 ostalo je sačuvano tako da je mogla obavljati zbrajanje i prebrojavanje s malim skupovima. Njena inteligencija bila je prosječna kao i jezične sposobnosti i radno pamćenje. Zanimljivo je da je njeno znanje o drugim semantičkim kategorijama (životinje, biljke, dijelovi tijela) ostalo sačuvano. S druge strane, postoje pacijenti s ozljedama temporalnog i frontalnog režnja kod kojih se javlja afazija, ali kod kojih je numeričko znanje sačuvano. Na primjer, pacijent HAB nije mogao razumjeti većinu izgovorenih ili napisanih riječi (Rosser, Warrington i Cipolotti, 1995). Mogao je izgovoriti samo nekoliko jednostavnih fraza kao što je „ne znam“. S druge strane, nije imao nikakvih problema s usporedbom brojeva po veličini ili s aritmetičkim operacijama, osim s množenjem. Sličan slučaj je i pacijent IH koji je imao semantičku demenciju odnosno teško oštećenje svih semantičkih kategorija, osim što mu je ostalo sačuvano numeričko znanje (Cappelletti, Butterworth i Kopelman, 2001). Iz ovih primjera možemo zaključiti da postoji dvostruka disocijacija između jezičnih i numeričkih sposobnosti,

odnosno da numeričko znanje i jezik imaju odvojenu neuralnu reprezentaciju, pri čemu je znanje o brojevima smješteno u parijetalnom režnju.

Kod mnogih pacijenata kod kojih se javljaju problemi s računanjem nakon ozljede lijevog parijetalnog režnja obično se javljaju i drugi poremećaji tvoreći takozvani Gerstmannov sindrom kojeg čine alkalkulija, agrafija, nesposobnost prepoznavanja prstiju i problemi s razlikovanjem lijevo - desno (Gerstmann, 1940). Gerstmannov sindrom najčešće nastaje nakon moždanog udara koji zahvati područje lijevog parijetalnog režnja odnosno preciznije područje u sredini IPS-a. Važno pitanje u vezi Gerstmannovog sindroma je u kojoj mjeri je on jedinstveni sindrom odnosno posljedica lezije točno određene kortikalne strukture koja obavlja četiri različite funkcije (računanje, jezik, motorika, vidno-prostorne funkcije) ili je moguće da se radi o zajedničkoj ozljedi četiri odvojena područja koja se slučajno nalaze blizu jedno drugog.

Simon i sur. (2002) su proveli fMRI snimanje zdravih ispitanika dok rješavaju zadatke računanja, usmjeravanja pažnje, pokreta očiju, pokazivanja prstima, dohvaćanje rukom i jezični zadatak detekcije fonema. Rezultati su pokazali da svi navedeni zadaci aktiviraju parijetalni režanj, ali da pri tome postoji sustavna topografska organizacija. Drugim riječima, svaki zadatak aktivira nešto drukčije područje kao da postoji četverokut u kojem je svaki kut zadužen za jednu funkciju, a također dolazi i do određenog preklapanja u neuronskoj aktivaciji. Međutim, postavlja se pitanje zašto ne bi postojali zasebni poremećaji koji bi nastali nakon ozljeda koje zahvaćaju samo jedan kut unutar predloženog četverokuta. Objašnjenje je da se sva ova područja unutar IPS-a opskrbljuju krvlju putem iste arterije (arterija angularnog girusa) čijim oštećenjem dolazi do zajedničkom poremećaja koji se manifestira kao Gerstmannov sindrom (Dehaene, Piazza, Pinel i Cohen, 2003).

1.2.2.6. Neurofiziološka istraživanja

Mjerenjem električne aktivnosti pojedinačnih neurona u mozgu primata otkriveni su neuroni osjetljivi za brojeve u lateralnom prefrontalnom korteksu (Nieder i sur., 2002; Nieder i Miller, 2003) i intraparijetalnom sulkusu (Nieder i Miller, 2004). U zadatku odgođenog uparivanja s uzorkom, od majmuna se traži da gleda dvije slike koje mu se prezentiraju jedna iza druge s malom vremenskom odgodom te da odredi jesu li dvije slike iste ili različite. Pri

tome, jedino bitno svojstvo po kojem se slike razlikuju je broj objekata na njima koji je varira od jedan do pet. Osnovno obilježje otkrivenih neurona koji su nazvani i numeroni je da imaju jedan određeni preferirani broj na kojeg maksimalno reagiraju. Tako imamo neurone osjetljive za jedan, dva tri, četiri ili pet objekata u vidnom polju. Nadalje, neuron čiji preferirani broj je primjerice tri pokazuje određenu aktivaciju i kada su prezentirana dva ili četiri objekta na slici. Drugim riječima, ovi neuroni imaju karakteristične krivulje podešenja, slično kao i drugi neuroni u vidnom sustavu koje se mogu opisati Gaussovom funkcijom. Krivulje podešenja ukazuju na to da kardinalitet skupa nije kodiran precizno, već uvijek postoji određena razina neuralnog šuma zbog koje može doći do konfuzije prilikom reprezentacije sličnih veličina. Na taj način mogao bi se objasniti efekt numeričke udaljenosti i veličine dobiven u kognitivnim eksperimentima. U skladu s tim, otkriveno je da kada majmun napravi grešku u odgovaranju, aktivnost neurona osjetljivog za odgovarajući broj je manja nego kada majmun da točan odgovor. Iz toga proizlazi da bi numeroni mogli činiti neuralnu osnovu mentalne numeričke linije (Nieder, 2005; Nieder i Dehaene, 2009).

Kao i u istraživanjima opisanima u prethodnim poglavljima, važno je bilo utvrditi reagiraju li numeroni doista na broj per se ili zapravo reagiraju na vidna obilježja podražaja kao što su ukupna površina, oblik, gustoća i sl. Mjerenja su pokazala da neuroni ne mijenjaju način reagiranja s obzirom na promjene vidnih karakteristika podražaja, već mijenjaju razinu aktivnosti jedino s promjenom brojnosti objekata što upućuje na apstraktno kodiranje broja. Kasnija istraživanja pokazala su da postoje neuroni osjetljivi i za veće brojeve (Nieder i Merten, 2007). Pri tome, zanimljivo je da je broj neurona osjetljivih za pojedinu veličinu skupa bio povezan s kardinalitetom skupa. Drugim riječima, najviše je bilo neurona osjetljivih za broj jedan, zatim za broj dva, broj tri, itd. Također, otkriveni su i neuroni osjetljivi za ordinalni poredak u nizu (Ninokura, Mushiaki i Tanji, 2003; 2004).

Roitman i sur. (2007) otkrili su novu vrstu neurona osjetljivih za brojeve u lateralnom intraparijetalnom korteksu koji nisu imali podešenost za određeni broj već su pokazivali monotoni porast aktivnosti u funkciji kardinaliteta skupa. Na sličan način kodirane su i neke druge senzorne veličine kao što je frekvencija titranja kože u somatosenzornom korteksu (Romo, Brody, Hernandez i Lemus, 1999; Brody, Hernandez, Zainos, Romo, 2003). Ovi neuroni funkcioniraju u skladu s modelom analognog integratora kojeg su predložili Gelman i Gallistel (1992, 2000). Međutim, Nieder i Dehaene (2009) smatraju da neuroni s monotonom osjetljivošću za brojeve čine dio iste neuronske mreže za detekciju brojnosti kao i neuroni s

podešenošću za broj pri čemu monotono kodiranje brojnosti predstavlja prvi sloj mreže koji daje ulaznu informaciju za drugi sloj u kojem su neuroni osjetljivi za pojedine brojeve.

1.2.2.7. Opća reprezentacija veličina

Iako mnogobrojna istraživanja ukazuju na povezanost prostora i brojeva, ostaje nejasno postoji li posebna prostorna reprezentacija u parijetalnom korteksu specijalizirana za brojeve. Prema teoriji o veličinama, parijetalni korteks sadrži opću reprezentaciju veličina koju dijele percepcija prostora, vremena, svjetlina, brzina i brojeva odnosno percepcija svih analognih ili kvantitativnih dimenzija (Walsh, 2003). Dakle, brojevi nemaju neki poseban status nego su dio šire neuronske mreže zadužene za stvaranje reprezentacije okoline koja će omogućiti kretanje u prostoru. Predikcije koje proizlaze iz ove teorije je da bi trebale postojati interakcije među analognim dimenzijama, a dio predikcija je i potvrđen (Buetti i Walsh, 2009). Jedna potvrda za ovu teoriju je postojanje numeričkog Stroopovog efekta ili efekta kongruentnosti veličina (Henik i Tzelgov, 1982). Kada ispitanici moraju što brže odrediti koji je od dva istovremeno prikazana broja numerički veći, njihov odgovor će biti brži u situaciji:

2 9

Nego u situaciji:

2 9

Dakle, fizička veličina podražaja stvara Stroopovu interferenciju s usporedbom numeričke veličine. Efekt se javlja i u obrnutom smjeru kada ispitanici uspoređuju brojeve po fizičkoj veličini, a zanemaruju numeričku veličinu. Povezanost reprezentacije fizičke veličine i brojeva potvrđena je i funkcionalnim oslikavanjem mozga (Pinel, Piazza, LeBihan i Dehaene,

2004). Također, u ventralnom intraparijetalnom režnju (VIP) primata otkriveni su neuroni koji pokazuju zajedničku osjetljivost za brojnost objekata i veličinu linija (Tudusciuc i Nieder, 2007).

Interakcija između brojeva i percepcije vremenskih intervala otkrivena je najprije kod miševa u istraživanju Churcha i Mecka (1984) koje je detaljno opisano u poglavlju 1.2.2.2. *Procjena brojnosti kod životinja*. Zanimljivo je da je davanje amfetamina miševima povećalo procjenu i vremenskih intervala i brojeva ukazujući na zajednički mehanizam za obje dimenzije. Kod ljudi se pokazalo da niz klikova dovodi do ubrzanja internalnog biološkog sata što je utjecalo na izvedbu u zadacima bisekcije linije, bisekcije numeričkih intervala i bisekcije vremenskih intervala (Droit-Volet, 2010). Nadalje, vrijeme je povezano i s drugim dimenzijama kao što pokazuje studija koju su proveli Xuan, Zhang, He i Chen (2007) gdje su ispitanici procjenjivali duže trajanje podražaji koji su veći, svjetliji i brojniji. Međutim, Eagleman (2008) osporava ovu vezu između procjene trajanja i drugih dimenzija budući da veći, svjetliji i brojniji podražaji zahtijevaju veću ukupnu količinu neuronske energije za kodiranje podražaja koja je samo indirektno povezana s procjenom trajanja vremenskog intervala. S druge strane, elektrofiziološka mjerenja u lateralnom intraparijetalnom režnju (LIP) otkrila su neurone koji pokazuju zajedničku osjetljivost za brojnost i vremenske intervale (Leon i Shadlen, 2003; Roitman, Brannon i Platt, 2007).

Pored interakcije između numeričke i fizičke veličine, istraživači su otkrili i interakciju između brojeva i svjetline. Cohen Kadosh i Henik (2006) koristili su zadatak usporedbe brojeva po veličini i dobili su da ispitanici brže reagiraju na male brojeve kada su prikazani u bijeloj nego u crnoj boji. S druge strane, kod velikih brojeva reakcija je bila brža u crnoj nego u bijeloj boji. Ovo ukazuje na postojanje zajedničke reprezentacije veličina za brojeve i svjetline pri čemu se svjetline preslikavaju na način da su svjetlije nijanse povezane s manjom veličinom. Zanimljivo je da i mala djeca povezuju male veličine s bijelom bojom a velike s crnom (Smith i Sera, 1992). Asocijacija malo-bijelo i veliko-crno prisutna je i kod osoba koje imaju sinesteziju tipa boja-brojka (Cohen Kadosh, Henik i Walsh, 2007). Međutim, u drugom kronometrijskom istraživanju dobiven je obrnuti rezultat odnosno reakcija na male brojeve je bila brža u crnoj nego u bijeloj boji, a za velike brojeve je bila brža u bijeloj nego u crnoj boji što ukazuje na obrnutu orijentaciju skale svjetlina (Cohen Kadosh, Cohen Kadosh i Henik, 2008). Također, u istraživanju su koristili i fMRI kako bi pokazali da postoji preklapanje u neuronskoj aktivaciji tijekom usporedbe svjetlina i usporedbe brojeva. Moguće objašnjenje ove razlike u rezultatima je da relevantna

kvantitativna dimenzija nije svjetlina nego kontrast (Gebuis i van der Smagt, 2011). Nedavno su Fumarola i sur. (2014) pokazali da ispitanici brže reagiraju lijevom rukom na tamnije nijanse sive boje, a desnom rukom na svjetlije. Isti efekt dobili su i u direktnom (usporedba svjetlina) i u indirektnom zadatku (usporedba boja) što ukazuje na preslikavanje malo-crno i veliko-bijelo koje je dobiveno istom paradigmom kao i kod SNARC efekta.

Nadalje, preslikavanje slično SNARC-u postoji i između visine tona i vertikalnog položaja u prostoru (Rusconi i sur., 2006). Ispitanici su morali odrediti je li ciljani ton viši ili niži od standarda. Kada je ton bio viši od standarda, ispitanici su brže reagirali pritiskom tipke koja se nalazila na višem položaju na tipkovnici (npr. tipku 6) nego kada je trebalo pritisnuti tipku na nižem položaju (npr. razmaknicu). Sličan efekt otkriven je i kod djece (Walker i sur., 2009). Isto tako, postoji veza između visine tona i percepcije njegovog trajanja budući da se viši tonovi procjenjuju da duže traju (Brigner, 1988). Ova pojava nazvana je auditorni kappa efekt. Također, što je veća razlika u visini između dva tona, to je veća i procjena trajanja pauze između njih (Crowder i Neath, 1995). Iako postoje brojni dokazi za povezanost među različitim kvantitativnim dimenzijama, Bonn i Cantlon (2012) zaključuju da i dalje ostaje neriješeno pitanje na kojoj razini obrade nastaju ove veze. Moguće je da su veze posljedica preslikavanja na zajedničku reprezentaciju veličina kao što to predlaže Walsh (2003; Buetti i Walsh, 2009), ali isto tako postoje i drugi putevi kao što je metaforičko ili konceptualno preslikavanje, a neke veze mogu biti i jednostavno naučene.

1.2.3. Sustav za automatsko prebrojavanje

Ljudi su sposobni brzo, točno i s velikom sigurnošću odrediti kardinalitet malog skupa objekata (do 4). Ovaj proces nazvan je subitizacija po latinskoj riječi *subitus* što znači brzo ili neposredno, a otkriven je prije više od sto godina kada je Jevons (1871) ispitivao svoju sposobnost procjene koliko komada graha ima u kutiji. Kasnija istraživanja potvrdila su i proširila Jevonsov nalaz (Kaufman, Lord, Reese i Volkmann, 1949; Mandler i Shebo, 1982). Kada se grafički prikaže odnos brzine prebrojavanja u funkciji broja objekata u vidnom polju dolazi do karakterističnog prekida na krivulji kod broja 4. Za skupove do 4 objekta, krivulja ima blagi rast od 40-100 ms po objektu dok za veće skupove, funkcija ima mnogo strmiji rast od 250-350 ms po objektu. Sličan oblik krivulje javlja se i kod broja grešaka, kao i kod procjene sigurnosti u odgovor. Zanimljivo je da postoje i velike individualne razlike u

sposobnosti subitizacije jer neki ljudi pokazuju prekid krivulje već kod broja 2, dok drugi ljudi mogu subitizirati i veće skupove od čak 6 objekata (Trick i Pylyshyn, 1993; 1994). Zanimljivo je da subitizacija nije ograničena samo na vidni modalitet. U novije vrijeme otkriveno je da je moguće subitizirati auditorne (Camos i Tillmann, 2008; Repp, 2007) i taktilne podražaje (Plaisier, Bergmann Tiest i Kappers, 2009).

Važno pitanje je da li se subitizacija oslanja na istu reprezentaciju brojeva na kojoj počiva približna procjena brojnosti (mentalna numerička linija ili neuralni integrator) ili zahtijeva zasebnu reprezentaciju. Karakteristike krivulje brzine prebrojavanja ukazuju na to da subitizacija počiva na brzom, paralelnom procesu koji ne zahtijeva napor, dok prebrojavanje većih skupova zahtijeva sporo i naporno premještanje pažnje s jednog objekta na drugi. S druge strane, Dehaene i Changeux (1993) te Gallistel i Gelman (1991) su pretpostavili da procjena brojnosti i za male i za velike skupove ovise o istom mehanizmu odnosno o procjeni brojnosti. U tom slučaju potrebno je objasniti zašto dolazi do prekida na krivulji brzine prebrojavanja. Prema ovim autorima, točnost procjene brojnosti i za male i za velike skupove slijedi Weberov zakon. Međutim, neuralni šum ili skalarni varijabilitet je za male skupove toliko mali da se ne može detektirati u vremenu reakcije i točnosti. Drugim riječima, mali skupovi ne zahtijevaju nikakav poseban mehanizam nego je kod njih percipirani pomak od jedne veličine do druge dovoljno velik da ga sustav za procjenu brojnosti s lakoćom razlikuje. Ovaj zaključak potkrepljuju neurofiziološka mjerenja neurona u mozgu majmuna koja pokazuju da nema prekida između reprezentacije velikih i malih brojeva (Nieder, 2005; Nieder, Freedman i Miller, 2002), kao i istraživanje funkcionalnim oslikavanjem mozga koje je pokazalo da nema razlike u aktivaciji mozga prilikom procjene malih i velikih brojnosti odnosno ne postoji poseban dio mozga koji se aktivira samo prilikom procjene malih brojnosti (Piazza, Mechelli, Butterworth i Prince, 2002).

Međutim, novija istraživanja ipak ukazuju na poseban status subitizacije. Revkin, Piazza, Izard, Cohen i Dehaene (2008) su pokazali da je identifikacija brojnosti u rasponu od 1 do 4 objekata mnogo preciznija nego u rasponu od 10 do 40 objekata, iako bi prema Weberovom zakonu razlikovanje jednog od dva objekta trebalo biti jednako precizno kao i razlikovanje između 10 i 20 objekata budući da je Weberov omjer u oba slučaja jednak. Nadalje, individualne razlike u kapacitetu za subitizaciju ne koreliraju s preciznošću procjene brojnosti odnosno s individualnim razlikama u Weberovom omjeru. Također, usmjeravanje pažnje na drugi zadatak utječe na subitizaciju, ali ne i na procjenu brojnosti (Burr, Turi i

Anobile, 2010) kao što i opterećivanje vidnog radnog pamćenja otežava subitizaciju, ali ne i procjenu brojnosti (Piazza, Fumarola, Chinello i Melcher, 2011).

Istraživanja sa predverbalnom djecom pokazuju kako djeca spontano prate broj objekata za skupove manje od 4. Na primjer, u jednom eksperimentu od desetomjesečnih beba je traženo da odaberu jednu od dvije kanticice s krekerima. Pri tome, djeca promatraju eksperimentatora dok stavlja u jednu kanticu jedan, a u drugu kanticu dva krekeri. Kada su trebali odabrati između 1 i 2 ili 2 i 3 krekeri djeca su spontano birala kanticu s većim brojem krekeri. Međutim, kada je trebalo izabrati između 3 i 4, 2 i 4, 3 i 6 ili 1 i 4 krekeri djeca su birala po slučaju iako je Weberov omjer kod izbora između 2 i 4 i 3 i 6 jednak kao i kod izbora između 1 i 2 krekeri, a u situaciji izbora između 1 i 4 krekeri čak i veći. Drugim riječima, izvedba na ovom zadatku nije ovisila o Weberovom omjeru nego o apsolutnom limitu koji je za djecu te dobi iznosio tri objekta (Feigenson, Carey i Hauser, 2002). Kasnije se pokazalo da se razlika između malih i velikih brojeva javlja i u drugim zadacima kao što je habituacija gdje djeca uspješno razlikuju 2 i 3 objekata, ali ne mogu razlikovati 4 i 6 objekata usprkos istom omjeru kao i u zadatku traženja skrivenih objekata (Feigenson i Carey, 2003; 2005). Nadalje, isti efekt precizne reprezentacije malih brojeva s ograničenjem do 3 dobiven je i kod percepcije niza zvukova (Lipton i Spelke, 2004) kao i kod vizualnih događaja kao što je skakanje lutki (Wood i Spelke, 2005). Štoviše, distinkcija se javlja i kod novorođenčadi (Coubart i sur., 2014).

Zaseban sustav za subitizaciju otkriven je i kod majmuna koji su rješavali sličan zadatak kao djeca s krekerima u kanticama (Hauser, Carey i Hauser, 2000). Majmunima se pokazivalo različiti broj kriški jabuka koje su skrivane na dvije lokacije. Majmuni su redovito birali lokaciju s većim brojem kriški kada je izbor bio između 1 i 2, 2 i 3 ili 3 i 4 kriške. Međutim, kada su morali birati između skupa od 3 i 8 ili između 4 i 8 kriški njihov odabir bio je slučajan. Isti limit od 4 objekta pokazao se i zadacima jednostavnog zbrajanja gdje su majmuni uspješno razlikovali točan rezultat od netočnog u situaciji $1 + 1$ ili $2 + 1$, ali nisu mogli razlikovati točan od netočnog odgovora kada je rezultat veći od 4 (Sulkowski i Hauser, 2001). Zanimljivo je da se distinkcija između sustava za male egzaktne brojeve i sustava za procjenu brojnosti ne javlja samo kod ljudi i majmuna nego postoji i kod riba (Agrillo, Piffer, Bisazza i Butterworth, 2012; Piffer, Agrillo i Hyde, 2012) kao i kod pilića (Rugani, Regolin i Vallortigara, 2008; 2010).

Novija neuroznanstvena istraživanja uspjela su izolirati zaseban kortikalni centar specijaliziran za male brojeve. Funkcionalnim oslikavanjem mozga tehnikom fMRI-a, Ansari i sur. (2007) su pokazali da kada ispitanici rješavaju zadatak usporedbe brojeva po veličini, dolazi do pojačane aktivacije desne temporo-parijetalne spojnice (temporo-parietal junction - TPJ) kada se uspoređuju mali brojevi. S druge strane, kada se uspoređuju veliki brojevi po veličini dolazi do smanjenja aktivacije TPJ-a i pojačane aktivacije IPS-a za kojeg se smatra da predstavlja neuralnu osnovu osjeta za brojeve. Slična razlika u aktivaciji TPJ-a i IPS-a dobivena je i kod prebrojavanja malih i velikih skupova objekata (Vetter, Butterworth i Bahrami, 2011). Mjerenjem elektromagnetskih valova izazvanih događajem (event related potentials - ERP), Hyde i Spelke (2009) su pokazali da sekvencijalna prezentacija dva mala skupa (od jednog do tri objekta) izaziva rani signal (N1) na posteriornim parijetalnim elektrodama. Pri tome, jačina signala varira samo s veličinom drugog skupa bez utjecaja veličine prvog skupa. S druge strane, veći skupovi objekata izazivaju kasniji signal (P2p) na posteriornim parijetalnim elektrodama pri čemu jačina signala varira ovisno o Weberovom omjeru između brojnosti dva skupa. Sličan efekt javlja se i kod predverbalne djece (Hyde i Spelke, 2011).

Trick i Pylyshyn (1994) su predložili model prema kojem subitizacija proizlazi iz generalnog mehanizma individuacije ili označavanja (indeksiranja) objekata u vidnom polju. Pod individuacijom se podrazumijeva proces kojim se objekti počinju percipirati kao specifične jedinice koje imaju svoj identitet i prostorni položaj. Pomoću indeksiranja vidni sustav određuje na koje objekte će se usmjeriti pažnja odnosno koji objekti će dobiti prioritet prilikom detaljne vidne obrade. Indeksiranje predstavlja sučelje između brzih, paralelnih procesa ranog vida i sporih, serijalnih kognitivnih procesa kao što su zaključivanje i rezoniranje (Pylyshyn, 2011). Kapacitet indeksiranja je ograničen na 4 do 5 objekata što odgovara rasponu subitizacije kao i kapacitetu vidnog radnog pamćenja (Luck i Vogel, 1997). Važnost radnog pamćenja za subitizaciju vidi se iz činjenice da postoji pozitivna korelacija između kapaciteta za subitizaciju i kapaciteta radnog pamćenja ali ne postoji korelacija između procjene brojnosti i kapaciteta radnog pamćenja (Piazza i sur., 2011).

Opisana istraživanja jasno pokazuju da je sustav za subitizaciju odvojen od sustava za procjenu brojnosti i da aktivira drugačije kognitivne i neuronske mehanizme. Međutim, ostaje nejasno da li se prilikom prezentacije malog skupa objekata aktiviraju oba sustava zajedno ili postoji podjela poslova. Cordes i Brannon (2009) su predložile dva moguća objašnjenja. Prema prvoj hipotezi, sustav za subitizaciju se aktivira samo za male skupove, a sustav za

brojnost samo za velike skupove, ali se u kasnijem koraku rezultat subitizacije preslikava na sustav za brojnost odnosno reprezentacija vidnih indeksa se pretvara u približnu veličinu. Druga hipoteza kaže da se oba sustava aktiviraju paralelno, ali u nekim situacijama sustav za subitizaciju preuzima kontrolu nad izvođenjem zadatka jer je nepreciznost u sustavu za brojnost prevelika. Hyde (2011) je predložio model prema kojem se sustav za subitizaciju aktivira onda kada postoje uvjeti za individuaciju odnosno za tretiranje svakog objekta kao zasebnu mentalnu jedinicu, dok se sustav za procjenu brojnosti aktivira samo u situaciji koja sprečava individuaciju i potiče tretiranje podražaja kao skupa.

1.2.4. Interakcije među sustavima

Slavni matematičar Jacques Hadamard proveo je sustavno anketiranje svojih kolega o tome kako razmišljaju dok rješavaju neki matematički problem. Zaključio je da je mnogim matematičkim otkrićima prethodio dugi period nesvjesne inkubacije nakon kojeg dolazi do iznenadnog uvida. Također, uočio je da se mnogi matematičari pozivaju na *intuiciju* kao osnovu za svoj rad. U tom smislu citirao je Einsteineovu izjavu: "Riječi, bilo izgovorene ili napisane, ne igraju nikakvu ulogu u mom procesu mišljenja. Mentalni entiteti koji služe kao elementi mojih misli su određeni znakovi ili slike, više ili manje jasne, koje mogu po volji dozvati ili kombinirati" (Hadamard, 1945; prema Dehaene, 2009, str. 232). Na sličan način, i Henry Poincare je isticao važnost intuicije za matematički rad. Problem s ovim uvidima je što nisu precizno definirali što je to intuicija. Prema Dehaene-u (2009) matematička intuicija oslanja se na osjet za brojeve odnosno na sustav za približnu procjenu brojnosti. Prema hipotezi o kulturalnom recikliranju neuronskih krugova, noviji kortikalni krugovi koji se razvijaju pod utjecajem kulture i učenja preuzimaju dio neuralnih resursa od starijih krugova (Dehaene i Cohen, 2007). Stoga, mora postojati veza između sustava za egzaktno brojeve i sustava za percepciju brojnosti. Potvrdu za ovu pretpostavku je postojanje efekta veličine i efekta udaljenosti kod egzaktnih brojeva. Nadalje, funkcionalnim oslikavanjem mozga kod ljudi utvrđeno je da postoji preklapanje neuralne aktivacije prilikom rješavanja zadataka procjene brojnosti i kod zadataka usporedbe egzaktnih brojeva (Piazza i sur., 2007).

Iako se navedeni rezultati čine razumljivi, postoje i istraživanja koja dovode u pitanje postojanje veze između egzaktnih brojeva i percepcije brojnosti. Koechlin i sur. (1999) su istraživali pripremu ponavljanjem (*repetition priming*) pri čemu su ispitanicima prezentirali

brojke ili skupove točkica. U situaciji kada je pripremajući podražaj bio istog formata kao i ciljni podražaj dolazilo je do efekta pripreme odnosno do ubrzanja vremena reakcije na ciljni podražaj. Međutim, kada se format pripremajućeg podražaja i ciljnog podražaja razlikovao, nije dolazio do efekta pripreme. Isti rezultat je dobiven i kod svjesne i kod nesvjesne pripreme odnosno i u situaciji kada je pripremajući podražaj prezentiran tako kratko da ga ispitanik ne može svjesno zamijetiti, kao i u situaciji kada je podražaj prezentiran dovoljno dugo da ga ispitanik može zamijetiti.

Nedavno su Lyons, Ansari i Beilock (2012) mjerili brzinu usporedbe brojeva po veličini u dva uvjeta: 1) kada je jedan broj prikazan brojkom a drugi kao skup točkica i 2) kada su oba broja prikazana kao skupovi točkica. Dobili su da je usporedba između dva različita formata značajno sporija nego kada se uspoređivalo veličine unutar istog formata. Nadalje, utvrdili su da ovaj efekt ne ovisi o veličini ili udaljenosti veličina koje se uspoređuju. Na osnovu toga, zaključili su da su brojke kao simboli "otuđene" od veličina koje predstavljaju. U istom smjeru, Cohen (2009) je pokazao da efekt numeričke udaljenosti kod usporedbe dva broja proizlazi iz perceptivne sličnosti brojki, a ne iz njihovog semantičkog značenja odnosno numeričke veličine. On je upotrijebio simbole za brojeve koji se sastoje od jednostavnih linija kao na starim digitalnim satovima kako bi precizno izmjerio perceptivnu sličnost i pokazao je da postoji veća sličnost između brojeva 4 i 5 nego 1 i 5. Do istog zaključka došli su i Garcia-Orza i sur. (2012) koji su pokazali da je perceptivna sličnost bolji prediktor vremena reakcije u zadatku usporedbe brojeva i kod Europljana koji koriste arapske brojke kao i kod Pakistanaca i Jordanaca koji koriste perzijske simbole za brojeve. Na kraju, 11 mjesečna longitudinalna studija s djecom u dobi od 6 godina pokazala je da mjere preciznosti sustava za brojnost ne daju značajan doprinos objašnjenju individualnih razlika u aritmetičkim vještinama povrh mjera znanja o egzaktnim brojevima (Göbel i sur, 2014). Autori zaključuju da su verbalni procesi povezani s učenjem oznaka za brojeve presudni za razvoj aritmetičkih vještina a ne djelovanje sustava za brojnost.

Mogući razlog zašto egzaktni brojevi i percepcija brojnosti nisu povezani je nepreciznost mentalne numeričke linije. Neurofiziološka istraživanja sugeriraju da u situaciji kada vidimo primjerice 26 točkica, aktivirat će se neuron koji je osjetljiv za broj 26, ali isto tako snažno će se aktivirati i neuroni koji su osjetljivi za brojeve 22, 23, 24, 27, 28 i 29. Zbog tog neuralnog šuma, ne može se uspostaviti jednoznačno preslikavanje između mentalne numeričke linije i reprezentacije brojevnih simbola što je preduvjet za shvaćanje egzaktnog broja. U skladu s tim, Izard i Dehaene (2008) su pokazali da je sposobnost preciznog

određivanja skupova točkica vrlo slaba. Pri tome su dobili da ispitanici sustavno podcjenjuju brojnost točkica. S druge strane, sustav za subitizaciju, iako neverbalan, omogućuje reprezentaciju egzaktnog broja. Međutim, veza između egzaktnih brojeva i sustava za subitizaciju nije dosad sustavno istražena kronometrijskom metodom.

1.2.4.1. Razvoj pojma egzaktnog broja kod djece

Zanimljivo pitanje je kako djeca uspijevaju savladati prirodne brojeve odnosno kako dolaze do ideje egzaktne jednakosti i funkcije nasljednik. Istraživanja kognitivnog razvoja pokazuju da djeca rano usvajaju riječi za brojeve te da ih koriste za prebrojavanje. Međutim, čini se da u početku djeca ne razumiju pojam egzaktnog broja već riječi za brojeve koriste kao lingvističku rutinu (Goswami, 2008). Jedno od prvih istraživanja prebrojavanja proveo je Saxe (1977) s djecom od 3, 4 i 7 godina. On je koristio različite zadatke kao što su precrtavanje gdje je na slici bio prikazan određen broj krugova, a dijete je moralo nacrtati jednak broj krugova ili se tražilo od djeteta da procjeni nalazi li se u dva niza poslaganih jedan pored drugog jednak broj igračaka (npr. 9 lutaka patki pored 11 lutaka riba). Pri tome, djeca koja nisu spontano počela brojati poticana su na to pitanjima kao što je *Da li bi brojenje pomoglo?* Saxe (1977) je pokazao da dolazi do nagle razvojne promjene u točnosti prebrojavanja između treće i četvrte godine. Nadalje, pokazao je da djeca prolaze razvojnu promjenu od pred-kvantitativnog brojenja u kojem se brojanje ne koristi sustavno kako bi se dobio isti broj do faze kvantitativnog brojenja u kojoj dijete razumije pojam egzaktne jednakosti i koristi ga kako bi riješio zadatak. Na primjer, dijete u fazi pred-kvantitativnog brojenja može prebrojati 9 lutaka patki, zatim 11 lutaka riba i na kraju zaključiti da se radi o istom broju. Da bi potvrdio ovaj nalaz, Saxe je dodatno proveo longitudinalnu studiju u kojoj je trogodišnjake pratio 18 mjeseci koristeći iste zadatke prebrojavanja. Dobio je da je prelazak od pred-kvantitativne do kvantitativne faze brojenja povezan s točnošću prebrojavanja i da imaju zajednički uzrok, a to je shvaćanje bijekcije odnosno jednoznačnog obostranog preslikavanja između riječi za brojeve i broja objekata u skupu.

Wynn (1990) je istraživala prebrojavanje malih skupova koristeći zadatak "daj mi broj" s djecom u dobi od 2.5, 3 i 3.5 godina. U tom zadatku, dijete se nalazi pred stolom na kojem se nalazi hrpa igračaka (lutke dinosaura). Od djeteta se traži da eksperimentatoru donese određeni broj igračaka. Zatim se pita dijete da provjeri da li je dalo ispravan broj kako

bi ga se potaknulo na prebrojavanje. Istraživanje je pokazalo da su djeca rješavala postavljeni zadatak na dva načina. Jedan način je sustavno prebrojavanje igračaka dok se ne dođe do traženog broja. Ovu skupinu djece Wynn (1990) je nazvala *brojači*. Druga djeca koju je Wynn nazvala *hvatači* samo bi zgrabila određeni broj igračaka i donijela ih eksperimentatoru bez prebrojavanja. Hvatači su bili točni kada se tražilo da se donese jedna igračka, pokazali su određenu tendenciju ka sustavnosti kada se tražilo dvije igračke, a s ostalim testiranim brojevima pogađali su po slučaju. U drugom dijelu istraživanja, Wynn je pokazala da do razvojnog pomaka od hvatača do brojača dolazi kada djeca imaju oko 3 i pol godine. U toj dobi djeca uspijevaju riječi za brojeve povezati s njihovim značenjem, odnosno s apstraktnim principima prebrojavanja.

Gelman i Gallistel (1978) su pretpostavili da djeca usvajaju principe prebrojavanja kao što su princip kardinaliteta, princip ordinaliteta i princip bijekcije. Ovi principi ne obuhvaćaju u potpunosti razumijevanje pojmova kardinaliteta i ordinaliteta. Na primjer, princip kardinaliteta označava prepoznavanje da zadnji broj u nizu predstavlja veličinu skupa. Ovaj princip Wynn (1990) je nazvala princip kardinalne riječi. Princip ordinaliteta označava prepoznavanje potrebe da se brojenje mora odvijati uvijek istim redoslijedom, a ne arbitrarno. Važno pitanje je odakle djeci znanje o principima prebrojavanja. Prema Leslie, Gallistel i Gelman (2007) djeca posjeduju urođenu sposobnost za reprezentaciju egzaktnih brojeva. Ona je zasnovana na urođenom pojmu broja jedan i funkciji nasljednik koji zajedno omogućavaju generiranje svih prirodnih brojeva. Pored toga, urođena je i pravilna mreža koju učenjem popunjavaju riječi za brojeve i vežu se uz određenu numeričku veličinu. Također, Leslie i sur. (2007) su razmotrili i drugačiji scenarij u kojem djeca imaju urođeno znanje o algebarskim principima koji upravljaju zaključivanjem o diskretnim veličinama. Jedan od tih principa je i egzaktna jednakost između simbola koja se kasnije može primijeniti na aritmetičke relacije odnosno na egzaktnu jednakost između numeričkih veličina. Bez obzira koji je od ova dva scenarija bliži stvarnom stanju, Leslie i sur. (2007) zaključuju da znanje o egzaktnim brojevima ne može biti zasnovano na mentalnoj numeričkoj liniji ili analognom integratoru jer su ove reprezentacije previše neprecizne te stoga mora postojati nezavisan sustav za egzaktne brojeve.

Nasuprot tome, Carey (2001; 2004) je predložila model u kojem znanje o brojevima proizlazi iz učenja i interakcije s okolinom, a ne iz urođenih kapaciteta. Važnu ulogu u ovom pristupu imaju lingvistički simboli odnosno riječi za brojeve kada se primjenjuju za prebrojavanje. Djeca prvo usvajaju značenje riječi za male brojeve (jedan, dva, tri) koje

povezuju s mentalnim modelima nastalima u sustavu za praćenje i označavanje objekata odnosno u sustavu za subitizaciju. Nakon određene prakse s prebrojavanjem, djeca sama spontano otkrivaju pravilo koje upravlja raspoređivanjem brojeva tokom prebrojavanja: dva je za jedan više od jedan, tri je za jedan više od dva. Nakon toga, otkriveno pravilo generaliziraju i na veće brojeve. U skladu s tim, Le Corre i Carey (2007) pokazali su da se značenje riječi za male brojeve do četiri usvaja prije shvaćanja principa prebrojavanja, a da se značenje riječi za veće brojeve usvaja oko šest mjeseci nakon principa prebrojavanja. Također, otkrili su da se kod procjene veličine skupova do četiri elementa ne javlja skalarni varijabilitet odnosno točnost procjene ne prati Weberov zakon što upućuje na zaključak da za procjenu veličine malih skupova nije odgovorna mentalna numerička linija. Međutim, Sarnecka i Gelman (2004) pokazale su da djeca koja još nisu usvojila principe prebrojavanja drugačije shvaćaju pojam puno od riječi za veće brojeve kao što su šest ili sedam. Dakle, djeca shvaćaju da riječ šest označava specifičnu numeričku veličinu (iako je još ne mogu pojmiti jer izlazi izvan raspona brojeva kojeg mogu egzaktno prebrojati) od pojma puno koji je neodređen. Iz toga su zaključile da djeca posjeduju određeno znanje o riječima za veće brojeve i prije nego što su usvojili principe prebrojavanja odnosno prije nego što su npr. preslikala riječ za šest na unutarnju reprezentaciju skupa od šest objekata.

Treća mogućnost je da principi prebrojavanja nastaju preslikavanjem riječi za brojeve na mentalnu numeričku liniju. Ovakvo preslikavanje opskrbljuje riječi za brojeve s približnim numeričkim značenjem, ali im ne omogućuje razumijevanje pojma egzaktnog broja odnosno kardinaliteta skupa. Međutim, analogne veličine mogu reprezentirati numerički poredak ($2 < 4 < 8$). Nadalje, preslikavanje između riječi i analogne reprezentacije omogućuje djeci da uoče analogiju između odnosa veličina na mentalnoj numeričkoj liniji i položaja riječi za brojeve na brojevnoj listi. Ova analogija omogućila bi djeci da nauče ključno obilježje liste riječi za brojenje, a to je da kasnije mjesto na listi za brojenje znači *veći skup* pri čemu je značenje pojma *veći skup* dan kroz aktivaciju mentalne numeričke linije. Također, moguće je da se principi prebrojavanja usvajaju putem preslikavanja riječi za brojeve na oba sustava istovremeno. Pri tome, djeca povezuju spoznaje do kojih su došli preslikavajući liste riječi na sustav za percepciju brojnosti i na sustav za subitizaciju. Dakle, principi prebrojavanja nastaju onda kada dijete uoči da sljedeća riječ na listi za brojenje znači dodaj jedan objekt u reprezentaciji i da to znači pomicanje za jedno mjesto udesno na mentalnoj numeričkoj liniji.

Kao što možemo vidjeti iz prethodnog pregleda, nije moguće dati jednostavan zaključak o interakciji između različitih sustava za reprezentaciju brojeva na osnovu razvojnih

istraživanja budući da nema jedinstvenog gledišta o ulozi sustava za brojnost i sustava za subitizaciju u razvoju pojma egzaktnog broja kod djece. Prema Carey (2004), subitizacija je ključni mehanizam za razvoj pojma broja budući da djeca povezuju riječi za brojeve s vidnim indeksima. S druge strane, Piazza (2010) smatra da je subitizacija manje važan sustav od osjeta za brojeve. Na kraju, Leslie i sur. (2007) i Butterworth (2010) zagovaraju tezu da ni subitizacija niti osjet za brojeve ne mogu biti kognitivna osnova za razvoj pojma egzaktnog broja već smatra da je taj pojam urođen i potpuno neovisan od ostalih sustava kao i od jezika (Butterworth i Gelman, 2005).

1.2.4.2. Kulturalne razlike u razumijevanju egzaktnih brojeva

Drugačiji pristup razmatranju uloge jezika u razvoju numeričkih pojmova pružaju istraživanja domorodačkih plemena s ograničenim rječnikom za brojeve. Gordon (2004) je istraživao numeričke sposobnosti pripadnika plemena Piraha koji žive u Brazilu. Jezik ovog plemena ima samo nazive za brojeve jedan, dva i mnogo. Međutim, čak i nazive jedan i dva koriste nekonzistentno. Gordon je koristio zadatke uparivanja u kojima eksperimentator na svom dijelu stola posloži određeni broj objekata (između jedan i sedam), a zatim traži od ispitanika da na svom dijelu stola posloži jednak broj drugih objekata. Na ovaj način može se ispitati sposobnost određivanja egzaktne jednakosti. Rezultati su pokazali da ispitanici rješavaju uspješno ovaj zadatak samo za brojeve jedan, dva i tri dok je za veće brojeve izvedba puno lošija. Na osnovu svojih istraživanja, Gordon (2004) je došao do kontroverznog zaključka da nedostatak riječi za brojeve onemogućuje razumijevanje pojma egzaktnog broja. Drugim riječima, Gordon smatra da je došao do potvrde za snažnu verziju hipoteze o lingvističkom determinizmu (Sapir-Whorfova hipoteza) prema kojem jezik oblikuje naše pojmove pa tako i pojam egzaktnog broja. Ovaj zaključak kritizirali su Gelman i Gallistel (2004) ukazujući na sustav za procjenu brojnosti kao na alternativni izvor znanja o brojevima koji ne ovisi o jeziku. Također, neuropsihologijska istraživanja pokazuju da se poremećaji jezika i poremećaji numeričkih vještina javljaju nezavisno.

Pica, Lemer, Izard i Dehaene (2004) su ispitivali sposobnost procjene brojnosti kod djece i odraslih pripadnika plemena Mundurucu koje također živi u Brazilu. U njihovom rječniku postoje nazivi za brojeve od jedan do pet. Zanimljivo je da riječi za veće brojeve ujedno imaju i više slogova. Također, ovo pleme ima doticaj s drugim kulturama budući da je

u kontaktu s brazilskom državnom administracijom, a dio pripadnika zna portugalski jezik. Zbog toga su Pica i sur. (2004) kreirali tri grupe ispitanika: 1) pripadnici plemena koji ne znaju portugalski jezik; 2) pripadnici plemena koji znaju portugalski jezik i 3) francuzi koji su služili kao kontrolna grupa. Rezultati su pokazali da sve tri grupe ispitanika posjeduju jednaku sposobnost uspoređivanja dva skupa točkica po veličini te sposobnost približnog zbrajanja i oduzimanja. Izvedba svih triju grupa slijedila je Weberov zakon što upućuje na djelovanje sustava za percepciju brojnosti. To vrijedi čak i za velike brojnosti (skup od 80 točkica) koji daleko nadmašuje rječnik za brojeve kojim raspolaže jezik naroda Munduruku. S druge strane, sposobnost za egzaktну aritmetiku Munduruku naroda ograničena je samo na male brojeve do 4 ili 5. Ovo istraživanje upućuje na zaključak da je osjet za brojeve univerzalan sustav jer se javlja u svim kulturama čak i u onima s ograničenim rječnikom za brojeve, dok je za shvaćanje pojma egzaktnog broja ipak potreban bogatiji rječnik za brojeve.

Međutim, Butterworth, Reeve, Reynolds i Lloyd (2008) su ispitivali australsku aboridžinsku djecu u rasponu dobi od 4 do 7 godina na zadacima egzaktnog uparivanja sličnima onima koje je koristio Gordon (2004). Uspoređivane su tri skupine djece od kojih jedna govori jezikom Warlpiri u kojem postoje riječi za jedan, dva i više od dva. Druga skupina djece govori jezikom Anindilyakwa u kojem postoje riječi za jedan, dva, tri i više od tri. Dakle, oba jezika imaju vrlo ograničen rječnik za brojeve. Treća skupina djece je govorila engleskim jezikom. Rezultati su pokazali da nema razlike u točnosti među skupinama na zadacima egzaktnog uparivanja. Iz toga proizlazi da razvoj pojma egzaktnog broja i sposobnosti za prebrojavanje ne ovisi o rječniku za brojeve koji neki jezik posjeduje, odnosno općenitije govoreći, razumijevanje egzaktnih brojeva ne može se svesti na razvoj jezika (Butterworth, 2010; Gelman i Butterworth, 2005). Zanimljivo pitanje je zašto prethodna istraživanja nisu našla potvrdu za razumijevanje pojma egzaktnog broja kod Piraha i Munduruku naroda. Butterworth i sur. (2008) smatraju da su metodološki detalji doprinijeli ovoj razlici jer je moguće da Piraha nisu uopće razumjeli što se od njih traži dok je zadatak oduzimanja kojeg su koristili Pica i sur. (2004) prilično težak. Buduća istraživanja korištenjem identične metodologije trebala bi pokazati mogu li se rezultati koje su dobili Butterworth i sur. (2008) replicirati i kod naroda Piraha i Munduruku.

1.2.5. Modeli numeričke spoznaje

1.2.5.1. McCloskey-ev apstraktni modularni model

McCloskey (1992; McCloskey i Maracuso, 1994; 1995) je predložio model numeričke obrade koji se sastoji od tri funkcionalno odvojena sustava koji međusobno komuniciraju putem apstraktnog kvantitativnog koda. Predloženi sustavi su:

1. Sustav za razumijevanje brojeva
2. Sustav za računanje
3. Sustav za produkciju brojeva

Sustav za razumijevanje brojeva pretvara različite površinske formate brojeva (brojke, napisane ili izgovorene riječi za brojeve) u zajednički apstraktni kod za veličine koji se koristi za daljnju obradu u sustavu za računanje i sustavu za produkciju brojeva. Apstraktni kod se sastoji od odvojene reprezentacije za jedinice, desetice, stotice itd. Drugim riječima, reprezentacija brojčanih veličina u modelu preslikava način prikaza brojeva u dekadskom brojevnom sustavu. Sustav za računanje čine zapamćene osnovne aritmetičke činjenice i pravila (npr., $6 + 7 = 13$, $7 * 9 = 63$, $0 + N = N$, $0 * N = 0$) kao i procedure za izvođenje složenijih aritmetičkih operacija kao što su zbrajanje i množenje višeznamenkastih brojeva. Nadalje, sustav za računanje može se podijeliti na odvojena memorijska skladišta za zbrajanje, oduzimanje, množenje i dijeljenje. Sustav za produkciju brojeva prima apstraktni kod od sustava za razumijevanje ili od sustava za računanje i pretvara ga natrag u specifični površinski format u kojem se daje odgovor na postavljeni numerički problem.

Glavna motivacija za McCloskey-ev model bila je objašnjavanje različitih vrsta grešaka i poteškoća pri rješavanju numeričkih zadataka kod pacijenata s ozljedom glave. Iz modela proizlazi da je moguće selektivno oštećenje za svaku aritmetičku operaciju kao što je moguće i selektivno oštećenje za činjenice i procedure. Sukladno ovoj pretpostavci otkriveni su pacijenti sa specifičnim deficitom za zbrajanje (van Harskamp i Cipolotti, 2001) ili za

dijeljenje (Cipolotti i De Lacy Costello, 1995). Na primjer, pacijent FS je s točnošću većom od 95% rješavao zadatke oduzimanja i množenja ali je ostvario samo 61.7% točnosti na zadacima zbrajanja s jednoznamenkastim brojevima. Isto tako, utvrđena je dvostruka disocijacija između oduzimanja i množenja odnosno otkriveni su pacijenti koji imaju problema s oduzimanjem, ali ne i s množenjem (van Harskamp i Cipolotti, 2001; van Harskamp, Rudge i Cipolotti, 2002) i obrnuto pacijenti koji su uspješno oduzimali, ali su griješili s množenjem (Cohen i Dehaene, 2000; Dehaene i Cohen, 1997). Nadalje, postoje pacijenti koji su izgubili znanje o procedurama iako im je sačuvano znanje o činjenicama kao što su pacijenti koji su znali tablicu množenja ali nisu znali da množenje s nulom daje nulu (McCloskey, 1992).

S druge strane, postoje i pacijenti koji su izgubili znanje o činjenicama, ali imaju sačuvano znanje o procedurama kao što je pacijent koji nije znao riješiti ni najjednostavnije zadatke zbrajanja s brojevima ali je znao rješavati zadatke s algebarskim izrazima tipa $(a + b) * c = (a * c) + (b * c)$ (Hittmair-Delazer, Sailer i Benke, 1995). Svi ovi nalazi govore u prilog McCloskeyevom modelu zato jer pokazuju da su sve četiri računske operacije spremljene u zasebnim skladištima te je moguće selektivno oštetiti bilo koju operaciju, a da ostale ostanu sačuvane. Isto tako, model posebno naglašava razlikovanje između numeričkog znanja i procedura te je moguće selektivno oštećenje ili znanja ili procedura. Međutim, Campbell (1992; 1994) je kritizirao ovaj model zbog činjenice da je podcijenio stupanj specifičnosti kodiranja numeričkih podražaja kao i stupanj interaktivnosti između komponentnih procesa. Preciznije, model ne može objasniti interakciju između površinskog formata i veličine problema koji je opisan u poglavlju 1.2.1.5.2. *Efekt formata*.

1.2.5.2. Dehaene-ov model trostrukog koda

Prema modelu trostrukog kodiranja kojeg je predložio Dehaene (1992; Dehaene i Cohen, 1995) brojevi se kodiraju unutar tri sustava: vidni sustav, slušno-verbalni sustav i sustav za numeričke veličine. Svaki sustav ima svoju zasebnu neuronsku osnovu. U vidnom sustavu brojevi su reprezentirani kao arapske znamenke tj. brojke. Vidni sustav je smješten bilateralno u fuziformnom girusu. Slušno-verbalni sustav u kojem su brojevi reprezentirani leksički (kao riječi) smješten je u lijevom angularnom girusu. Međutim za razumijevanje odnosa među brojevima najvažniji je neverbalni sustav za numeričke veličine koji je smješten

bilateralno u intraparijetalnom sulkusu. Upravo ovaj sustav smatra se odgovornim za postojanje interakcije između prostora i brojeva jer se u njemu nalazi tzv. mentalna numerička linija koja koristi prostor kako bi reprezentirala veličine odnosno semantiku brojeva.

Prema modelu trostrukog koda, moguće je transkodiranje bez aktiviranja sustava za veličinu. Drugim riječima, postoje obostrane veze između sva tri sustava što znači da verbalni sustav može direktno aktivirati vizualni sustav i obrnuto, a da se pri tome ne aktivira sustav za veličine. Nadalje, model pretpostavlja da se različite aritmetičke operacije oslanjaju na različite sustave kodiranja. Na primjer, zbrajanje malih brojeva može se izvršiti putem doziva iz verbalnog sustava gdje su pohranjene aritmetičke činjenice. Kod zbrajanja većih brojeva aktivira se sustav za veličine. Oduzimanje se u većoj mjeri od zbrajanja oslanja na sustav za veličine. S druge strane, množenje i dijeljenje se u mnogo većoj mjeri oslanjaju na doziv činjenica iz verbalnog sustava budući da tablicu množenja učimo napamet. Iz toga proizlazi da bi trebala postojati dvostruka disocijacija između oduzimanja i množenja kod neuropsihologijskih pacijenata kao što je i potvrđeno u više studija (Cohen i Dehaene, 2000; Dehaene i Cohen, 1997; Van Harskamp i Cipolotti, 2001; van Harskamp i sur., 2002). Međutim, ne bi smjeli postojati selektivni poremećaji za zbrajanje (van Harskamp i Cipolotti, 2001) ili dijeljenje (Cipolotti i De Lacy Costello, 1995) te je njihovo postojanje veliki problem za model trostrukog koda. Također, model ne radi jasnu distinkciju između numeričkog znanja i numeričkih procedura kao što to radi McCloskeyev model (1992). Niti ovaj model ne može objasniti interakciju između površinskog formata i veličine problema (Campbell, 1994).

1.2.5.3. Campbellova hipoteza o kompleksu kodiranja

Hipoteza o kompleksnosti kodiranja uključuje tri pretpostavke (Campbell i Clark 1988; 1992): 1) obrada brojeva odvija se u sustavima za specifične modalitete (vidni, vidno-prostorni i fonološki kod) a ne u odvojenom apstraktnom kodu; 2) različiti površinski formati brojeva mogu direktno utjecati na izbor strategije, procesa ili kodova koji će se koristiti tijekom rješavanja zadatka i 3) ista numerička funkcija (dozivanje numeričkih činjenica iz pamćenja) može uključivati više različitih kodova. Isto tako, svaki kod može biti uključen u izvršavanje različitih numeričkih funkcija. Campbell (1994) je napomenuo da se hipoteza o kompleksu kodiranja ne treba promatrati kao potpuno razvijeni model numeričke spoznaje

već kao polazišnu osnovu iz koje se mogu razviti različiti modeli. Pri tome, polazišnu osnovu čine odbacivanje apstraktnog numeričkog koda i jednostavne modularne arhitekture u kojoj nema interakcije među komponentnim procesima. Osnovni argument za ovu hipotezu je postojanje interakcije između površinskog formata i veličine problema koju ne mogu objasniti niti McCloskey-ev model niti Dehaene-ov model trostrukog koda. Ovaj model nije moguće jednostavno evaluirati s obzirom na postojeće bihevioralne ili neuropsihologijske nalaze budući da nije precizno specificiran, odnosno ne predlaže precizne mehanizme reprezentacije brojeva niti aritmetičkog znanja i procedura.

1.2.6. Zaključno o numeričkoj spoznaji

U ovom dijelu uvoda su prikazane suvremene spoznaje o kognitivnim i neuronskim sustavima koji se nalaze u podlozi razumijevanja prirodnih brojeva. Prvi sustav, karakterističan samo za ljude, omogućuje razumijevanje egzaktnih brojeva i njihovu fleksibilnu primjenu kod kardinalnog, ordinalnog i nominalnog označavanja. Kronometrijskim istraživanjima otkriveno je nekoliko pojava kao što su efekt veličine, efekt udaljenosti i SNARC efekt koji ukazuju na to da se značenje egzaktnog broja oslanja na evolucijski stariji sustav za približnu procjenu brojnosti. Ovaj sustav prisutan je kod predverbalne djece i drugih vrsta, a brojnost reprezentira pomoću mentalne numeričke linije ili neuralnog integratora. Treći sustav osigurava automatsko i točno prebrojavanje malih skupova. Ovaj sustav povezan je s pažnjom i radnim pamćenjem odnosno indeksiranjem ili individualizacijom objekata i također je prisutan kod predverbalne djece i drugih vrsta. Neuroznanstvena istraživanja pokazuju da postoje odvojeni neuronski krugovi za reprezentaciju egzaktnih brojeva, približne brojnosti i malih skupova. Na kraju, opisana su istraživanja o mogućim interakcijama među sustavima budući da i dalje ostaje neriješeno pitanje u kojoj mjeri razumijevanje pojma egzaktnog broja ovisi o jeziku te o sustavu za procjenu brojnosti i sustavu za brzo prebrojavanje.

2. PROBLEM ISTRAŽIVANJA

Osnovni problem rada je pitanje zasniva li se razumijevanje numeričkih pojmova na utemeljenju u percepciji kako to predlaže teorija perceptivnih simboličkih sustava (Barsalou, 1999). Ovaj problem može se razložiti na veći broj podproblema. Jedan skup problema odnosi se na utemeljenje brojeva u prostornoj reprezentaciji odnosno mentalnoj numeričkoj liniji. Prethodna istraživanja upućuju na zaključak da se značenje broja dohvaća putem aktiviranja točke na horizontalno položenoj numeričkoj liniji, pri čemu pozicija točke odgovara veličini tog broja (Dehaene i sur., 1998; Fias i Fischer, 2005). Nadalje, sukladno teoriji o veličinama (Walsh, 2003) istraživanja ukazuju na postojanje implicitne veze između brojeva i boja koja ima ishodište u zajedničkoj reprezentaciji veličina (Cohen Kadosh i sur., 2008; Fumarola i sur., 2014; Gebuis i van der Smagt, 2011; Ren i sur., 2011). Stoga se može postaviti pitanje hoće li se veza između brojeva i boja generalizirati i na situaciju zbrajanja i oduzimanja. Naime, ove aritmetičke operacije možemo promatrati kao kretanje duž mentalne numeričke linije, pri čemu zbrajanje zahtijeva kretanje s lijeva na desno, dok oduzimanje zahtijeva kretanje s desna na lijevo. Iz toga proizlazi nekoliko istraživačkih problema:

1. Ispitati postoji li interakcija između boje i aritmetičkih operacija. Preciznije, postoji li razlika u brzini rješavanja zadataka zbrajanja i oduzimanja kada su prezentirani u bijeloj i crnoj boji.
2. Ispitati postoji li razlika u brzini obrade pozitivnih i negativnih brojeva kada su prezentirani u bijeloj i crnoj boji, kako bismo vidjeli da li se mogući efekt boje na aritmetičke operacije opisan u prethodnom problemu, zapravo svodi na različito reagiranje na znakove plus i minus i njihovu moguću vezu s mentalnom numeričkom linijom.
3. Ispitati javlja li se utjecaj boje na brzinu rješavanja aritmetičkih operacija i u situaciji kada ispitanici rješavaju samo zadatke zbrajanja ili samo zadatke oduzimanja unutar istog bloka pokušaja. Na ovaj način želimo provjeriti je li veza između boje i aritmetičkih operacija možda posljedica kategorijalnog kodiranja odnosno registriranja kategorijalnih suprotnosti crno-bijelo i zbrajanje-oduzimanje, a ne preslikavanja na zajedničku reprezentaciju veličina (Lakens i sur., 2012).

4. Ispitati javlja li se interakcija između boje i aritmetičkih operacija kod zadataka množenja i dijeljenja.

Drugi skup problema odnosi se na pitanje utemeljenja brojeva u sustavu za subitizaciju odnosno brzo prebrojavanje elemenata u vidnom polju. Prethodna istraživanja s numeričkim Stroopovim efektom pokazuju da postoji interferencija između broja znamenki i njihovog numeričkog značenja kada je zadatak ispitanika odrediti koliko znamenki je prikazano (Shor, 1971; Wendes, 1968). Međutim, takav zaključak kritizirali su Pansky i Algom (1999; 2002) tvrdeći da ova interferencija nastaje zbog toga što je jedan dio numeričke obrade (određivanje brojnosti znamenki) relevantan za zadatak i dovodi do okidanja (triggering) drugih aspekata numeričke obrade. Drugim riječima, karakteristike zadatka usmjeravaju pažnju ispitanika na odnos između znamenke i njenog značenja te se ne može govoriti da je ta veza automatska već je posljedica zahtjeva samog zadatka. Stoga se može postaviti pitanje je li moguće kreirati zadatak u kojem će oba aspekta numeričke obrade (i simbol i brojnost) biti irelevantni. S tim u vezi mogu se postaviti dva problema:

5. Ispitati postoji li interakcija između brojeva i veličine koju oni označavaju u situaciji kada niti broj niti numerička veličina nisu relevantni za zadatak jer se kao zadatak koristi određivanje sukladnosti oblika objekta i riječi za objekt koja je spomenuta u jednostavnoj frazi prije prezentacije objekta.

6. Ispitati može li se efekt opisan u prethodnom problemu generalizirati i na situaciju u kojoj se u zadatku koriste cijele rečenice umjesto jednostavnih fraza, čime se još više smanjuje mogućnost slučajnog okidanja automatskog procesa koji povezuje brojeve i njihovu brojnost.

3. HIPOTEZE

Na osnovu dosadašnjih istraživanja o interferenciji između boja i brojeva (Cohen Kadosh i sur., 2008; Gebuis i van der Smagt, 2011) te istraživanja o vezi između boja i prostorne reprezentacije veličina (Fumarola i sur., 2014; Ren i sur., 2011) možemo postaviti sljedeće hipoteze:

1. Postoji interakcija između brzine rješavanja aritmetičkih operacija i boje kojom su aritmetički problemi prikazani. Preciznije, zadaci zbrajanja rješavaju se brže kada su prezentirani u bijeloj nego u crnoj boji. S druge strane, zadaci oduzimanja brže se rješavaju kada su prezentirani u crnoj nego u bijeloj boji.

2. Ne postoji razlika u brzini obrade pozitivnih i negativnih brojeva kada su prezentirani u bijeloj i crnoj boji. Ova hipoteza proizlazi iz istraživanja koja pokazuju da se negativni brojevi tretiraju kao kompozitni pojam koji se sastoji od dvije komponente: predznaka i broja (Ganor-Stern i Tzelgov, 2008; Shaki i Petrusic, 2005). Dakle, ne postoji reprezentacija negativnih brojeva na mentalnoj numeričkoj liniji pa se oni ne bi trebali preslikavati niti na boje.

3. Razlika u brzini rješavanja aritmetičkih operacija prikazanih u bijeloj i crnoj boji javlja se i u situaciji kada ispitanici rješavaju samo zadatke zbrajanja ili samo zadatke oduzimanja unutar istog bloka pokušaja zato jer grupiranje operacija u blokove ne bi trebalo poremetiti kretanje duž mentalne numeričke linije. Dakle, kada rješavaju zadatke zbrajanja, ispitanici će biti brži kada je zadatak prikazan u bijeloj nego u crnoj boji. S druge strane, kada rješavaju zadatke oduzimanja, ispitanici će biti brži kada je zadatak prikazan u crnoj nego u bijeloj boji.

4. Ne postoji interakcija između brzine rješavanja aritmetičkih operacija i boje kod množenja i dijeljenja zato što ove operacije ne ovise o kretanju duž mentalne numeričke linije, već o dozivu iz dugoročnog pamćenja (npr. tablicu množenja učimo napamet).

S obzirom na pitanje utemeljenja brojeva u sustavu za subitizaciju, možemo postaviti sljedeće hipoteze:

5. Postoji interferencija između brojeva i veličine koju oni označavaju i u situaciji kada niti broj niti numerička veličina nisu relevantni za zadatak kojeg ispitanici rješavaju. Preciznije,

očekujemo pojavu interferencije odnosno sporije rješavanje zadatka kada broj spomenut u frazi i brojnost objekata na slici nisu sukladni, nego kada jesu sukladni.

6. Očekuje se da se isti efekt interferencije opisan prethodno pojavi i u situaciji kada se prezentiraju cijele rečenice umjesto fraza.

4. METODA

4.1. Eksperiment 1

Nacrt istraživanja

U Eksperimentu 1 korišten je faktorski nacrt $2 \times 2 \times 2$ s ponavljanim mjerenjima na sva tri faktora. Nezavisne varijable bile su:

1. Boja podražaja na dva nivoa: crna ili bijela
2. Aritmetička operacija na dva nivoa: zbrajanje ili oduzimanje (prikazana brojevima kao simbolima)
3. Vrsta odgovora na dva nivoa: da ili ne, pri čemu odgovor DA znači da su lijeva i desna strana jednadžbe jednake, a odgovor NE da nisu jednake

Zavisne varijable u eksperimentu bile su izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovao 31 student preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2009/2010), od čega 27 studentica i 4 studenata u rasponu dobi od 19 do 26 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađivalo se bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

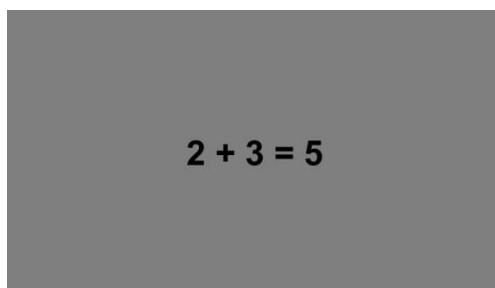
Eksperiment je proveden na računalu s 19 inčnim CRT monitorom, a podražaji su prezentirani u računalnom programu E-prime 2.0 (Schneider, Eschman i Zuccoloto, 2002). Odgovori ispitanika prikupljani su pomoću Serial Response Box-a s milisekundnom preciznošću (proizvođač: Psychological Software Tools, Inc.).

Postupak

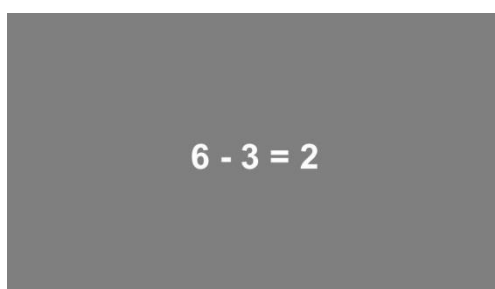
Ispitivanje je provedeno u Laboratoriju za eksperimentalnu psihologiju na Filozofskom fakultetu u Rijeci, individualno sa svakim ispitanikom. Podražaji u ovom eksperimentu bili su numerički izrazi zbrajanja i oduzimanja. Numerički izraz sastojao se od lijeve i desne strane

jednadžbe, pri čemu je lijeva strana predstavljala problem od dva člana izražen kao zbrajanje dva pribrojnika ili kao oduzimanje umanjenika i umanjitelja, a desna strana činila je mogući zbroj u zadacima zbrajanja (točan ili netočan), odnosno razliku u zadacima oduzimanja (točnu ili netočnu). Svaki problem na lijevoj strani jednadžbe uključivao je znamenke u rasponu od 2 do 9, čiji je rezultat mogao biti u rasponu od 4 do 18 kod zadataka zbrajanja, a od 0 do 7 kod zadataka oduzimanja. Kako bi se izbjegli negativni brojevi u rezultatu oduzimanja, pazilo se da umanjenik bude uvijek veći od umanjitelja. Za netočne izraze, rezultat je izabran pseudoslučajno da bude u rasponu od ± 3 od točnog rješenja. 18 zadataka zbrajanja i 18 zadataka oduzimanja, uključujući i zadatke s istim znamenkama (npr. $3 + 3 = 6$) u svakoj operaciji, pojavili su se dva puta kao točan problem (jednom u bijeloj i jednom u crnoj boji) i dva puta kao netočan problem (jednom u bijeloj i jednom u crnoj boji), što je činilo ukupno 144 pokušaja. Udaljenost između prve i ponovne prezentacije istog problema iznosila je najmanje 18 pokušaja. Liste korištenih aritmetičkih problema nalaze se u *Prilogu 9.1*.

Svaki pokušaj započeo je fiksacijskim znakom (x x x x x) u žutoj boji koji je prezentiran na sredini ekrana. Ispitanicima je rečeno da istovremeno pritisnu obje tipke (krajnje lijevu i krajnje desna tipku na response box-u) kada su spremni za prezentaciju podražaja. Pritiskom obje tipke istovremeno fiksacijski znakovi su se povećali u Arial font veličine 24 u trajanju 500 ms, nakon čega je uslijedila prezentacija podražaja odnosno aritmetičkog problema u bijeloj ili crnoj boji, također u fontu Arial veličine 24. Aritmetički problem ostao je na ekranu sve do odgovora ispitanika. Pozadina ekrana na kojoj su prezentirani podražaji bila je srednje siva za vrijeme čitavog eksperimenta. Zadatak ispitanika bio je odgovoriti je li lijeva strana jednadžbe jednaka desnoj strani pritiskom na tipku DA ili tipku NE (krajnje tipke na response box-u). Polovica ispitanika odgovarala je DA pritiskom kažiprsta lijeve ruke na lijevu tipku, a druga polovica ispitanika pritiskom kažiprsta desne ruke na desnu tipku (i obrnuto za odgovor NE). Nakon svakog pokušaja ispitanici su dobili povratnu informaciju o točnosti u trajanju od 500 ms prije sljedećeg pokušaja: riječ TOČNO u zelenoj boji u slučaju točnog odgovora ili riječ NETOČNO u crvenoj boji u slučaju netočnog odgovora. Prije eksperimentalnog bloka ispitanicima je bilo prezentirano 12 pokušaja za vježbu s aritmetičkim problemima koji nisu korištenu u eksperimentalnom bloku, uključujući znamenke 0 i 1 kao operante (npr. $7 + 0 = 7$). Eksperimentalni blok je podijeljen u dva bloka s 72 pokušaja između kojih je bila kratka pauza. Redoslijed prezentacije problema bio je randomiziran unutar svakog bloka za svakog ispitanika.


$$2 + 3 = 5$$

Slika 4.1. Primjer aritmetičkog zadatka (operacija zbrajanja u crnoj boji)


$$6 - 3 = 2$$

Slika 4.2. Primjer aritmetičkog zadatka (operacija oduzimanja u bijeloj boji)

Uputa koje su ispitanici dobili glasila je ovako:

U ovom eksperimentu od Vas će se tražiti da odredite je li lijeva strana jednadžbe jednaka desnoj odnosno odgovara li zbroj ili razlika dva broja prezentirana lijevo od znaka jednakosti rezultatu prezentiranom desno od znaka jednakosti. Ako su lijeva i desna strana jednake pritisnite krajnje desnu tipku (tipku DA), a ako nisu jednake pritisnite krajnje lijevu tipku (tipku NE). (Polovica ispitanika odgovarala je obrnuto!)

Tipke pritišćete kažiprstima lijeve i desne ruke i jako je bitno da kažiprste obje ruke držite na tipkama za vrijeme trajanja čitavog eksperimenta.

Prvo će Vam biti prezentirani mali fiksacijski križići (xxxxx) i tada se trebate pripremiti za prezentaciju podražaja. Kada ste spremni, pritisnite obje tipke za odgovor istovremeno. Kada to učinite, križići će se povećati i uslijediti će prezentacija podražaja na koji trebate odgovoriti pritiskom lijeve ili desne tipke.

Nakon svakog odgovora biti će Vam prezentirana povratna informacija o točnosti Vašeg odgovora prije sljedećeg pokušaja. U ovom eksperimentu mjere se brzina i točnost odgovara.

Trudite se odgovarati što brže i što točnije možete!

Prije samog eksperimenta biti će Vam prezentirana serija pokušaja za vježbu.

Za početak vježbe pritisnite bilo koju tipku.

Sada slijedi eksperiment.

Podsjetimo, ako su lijeva i desna strana jednadžbe jednake pritisnite krajnje desnu tipku (tipku DA), a ako nisu jednake pritisnite krajnje lijevu tipku (tipku NE). Na malim fiksacijskim križićima trebate pritisnuti obje tipke istovremeno.

Pripremite se, stavite kažiprste na tipke za odgovore i kada ste spremni za početak eksperimenta, pritisnite bilo koju tipku.

Sretno!

4.2. Eksperiment 2

Nacrt istraživanja

U Eksperimentu 2 korišten je faktorski nacrt $2 \times 2 \times 2$ s ponavljanim mjerenjima na sva tri faktora. Nezavisne varijable bile su:

1. Boja podražaja na dva nivoa: crna ili bijela
2. Aritmetička operacija na dva nivoa: zbrajanje ili oduzimanje (prikazana riječima za brojeve umjesto simbolima)
3. Vrsta odgovora na dva nivoa: da ili ne, pri čemu odgovor DA znači da su lijeva i desna strana jednadžbe jednake, a odgovor NE da nisu jednake

Zavisne varijable u eksperimentu bile su izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovalo 30 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2010/2011), od čega 21 studentica i 9 studenata u rasponu dobi od 19 do 23 godine. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađivalo se bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Eksperiment je proveden na računalu s 19 inčnim CRT monitorom, a podražaji su prezentirani u računalnom programu E-prime 2.0. Odgovori ispitanika prikupljani su pomoću Serial Response Box-a s milisekundnom preciznošću (proizvođač: Psychological Software Tools, Inc.).

Postupak

Postupak i podražaji bili su identični kao u Eksperimentu 1, osim što su brojevi (simboli) zamijenjeni riječima za brojeve. Tako je na primjer umjesto aritmetičkog problema $2 + 3 = 5$ prezentiran problem u obliku: dva + tri = pet.



Slika 4.3. Primjer aritmetičkog zadatka (operacija zbrajanja u crnoj boji)



Slika 4.4. Primjer aritmetičkog zadatka (operacija oduzimanja u bijeloj boji)

Uputa koju su ispitanici dobili bila je jednaka uputi iz Eksperimenta 1, uz napomenu da će im numerički izrazi biti prezentirani riječima umjesto simbolima za brojeve.

4.3. Eksperiment 3

Nacrt istraživanja

U Eksperimentu 3 korišten je faktorski nacrt $2 \times 2 \times 2$ s ponavljanim mjerenjima na sva tri faktora. Nezavisne varijable bile su:

1. Boja podražaja na dva nivoa: crna ili bijela
2. Predznak na dva nivoa: pozitivan ili negativan
3. Vrsta odgovora (paritet) na dva nivoa: da ili ne, pri čemu odgovor DA znači da je broj paran, a odgovor NE da je neparan

Zavisne varijable u eksperimentu bile su izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovao 45 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2010/2011), od čega 38 studentica i 7 studenata u rasponu dobi od 19 do 25 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađivalo se bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Eksperiment je proveden na računalu s 19 inčnim CRT monitorom, a podražaji su prezentirani u računalnom programu E-prime 2.0. Odgovori ispitanika prikupljani su pomoću Serial Response Box-a s milisekundnom preciznošću (proizvođač: Psychological Software Tools, Inc.).

Postupak

Ispitivanje je provedeno u Laboratoriju za eksperimentalnu psihologiju na Filozofskom fakultetu u Rijeci, individualno sa svakim ispitanikom. Podražaji u ovom eksperimentu bili su brojevi od -9 do 9, bez brojeva 0, 5 i -5. Svaki broj bio je prezentiran u sredini ekrana i pojavio se pet puta u crnoj i pet puta u bijeloj boji što je ukupno činilo 160 pokušaja. Redoslijed prezentacije brojeva bio je randomiziran za svakog ispitanika uz pravilo da se ne mogu prezentirati četiri parna ili neparna broja uzastopce. Svaki pokušaj započeo je

prezentacijom fiksacijskog znaka (X) u zelenoj boji na sredini ekrana u trajanju 500 ms. Nakon fiksacijskog znaka uslijedila je prezentacija broja u bijeloj ili crnoj boji (font arial, veličina 42) koji je ostao na ekranu do trenutka odgovora. Ispitanicima nije davana povratna informacija o uratku. Zadatak ispitanika bio je odgovoriti je li prezentirani broj paran ili nije, pritiskom na tipku DA ili tipku NE (krajnje tipke na response box-u). Polovica ispitanika odgovarala je DA pritiskom kažiprsta lijeve ruke na lijevu tipku, a druga polovica ispitanika pritiskom kažiprsta desne ruke na desnu tipku (i obrnuto za odgovor NE).

4.4. Eksperiment 4

Nacrt istraživanja

U Eksperimentu 4 korišten je faktorski nacrt 2×2 s ponavljanim mjerenjima na oba faktora. Nezavisne varijable bile su:

1. Boja podražaja na dva nivoa: crna ili bijela
2. Vrsta odgovora na dva nivoa: da ili ne, pri čemu odgovor DA znači da su lijeva i desna strana jednadžbe jednake, a odgovor NE da nisu jednake (u zadacima zbrajanja)

Zavisne varijable su bile izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovalo 30 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2011/2012), od čega 25 studentica i 5 studenata u rasponu dobi od 19 do 23 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađeno je s bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Identičan kao i u prethodnim eksperimentima.

Postupak

Identičan kao i u Eksperimentima 1 i 2. Prikazano je 144 zadatka zbrajanja od kojih 72 u bijeloj a 72 u crnoj boji. Unutar skupa bijelih i crnih podražaja polovica zadataka je bilo točno, a polovica netočno. Liste korištenih aritmetičkih problema nalaze se u *Prilogu 9.2*.

4.5. Eksperiment 5

Nacrt istraživanja

U Eksperimentu 5 korišten je faktorski nacrt 2×2 s ponavljanim mjerenjima na oba faktora. Nezavisne varijable bile su:

1. Boja podražaja na dva nivoa: crna ili bijela
2. Vrsta odgovora na dva nivoa: da ili ne, pri čemu odgovor DA znači da su lijeva i desna strana jednadžbe jednake, a odgovor NE da nisu jednake (u zadacima oduzimanja)

Zavisne varijable su bile izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovalo 26 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2012/2013), od čega 22 studentice i 4 studenta u rasponu dobi od 19 do 23 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađeno je s bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Identičan kao i u prethodnim eksperimentima.

Postupak

Identičan kao i u Eksperimentima 1 i 2. Prikazano je 144 zadatka oduzimanja od kojih 72 u bijeloj a 72 u crnoj boji. Unutar skupa bijelih i crnih podražaja polovica zadataka je bilo točno, a polovica netočno. Liste korištenih aritmetičkih problema nalaze se u *Prilogu 9.3*.

4.6. Eksperiment 6

Nacrt istraživanja

U Eksperimentu 6 korišten je faktorski nacrt $2 \times 2 \times 2$ s ponavljanim mjerenjima na svim faktorima. Nezavisne varijable bile su:

1. Boja podražaja na dva nivoa: crna ili bijela
2. Aritmetička operacija na dva nivoa: množenje ili dijeljenje
3. Vrsta odgovora na dva nivoa: da ili ne, pri čemu odgovor DA znači da su lijeva i desna strana jednadžbe jednake, a odgovor NE da nisu jednake

Zavisne varijable su bile izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovalo 24 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2012/2013), od čega 23 studentica i 1 student u rasponu dobi od 19 do 26 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađeno je s bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Identičan kao i u prethodnim eksperimentima.

Podražaji

144 aritmetička problema oblika $2 * 3 = 6$ ili $9 / 3 = 2$ od kojih je polovica prikazana u bijeloj boji, a druga polovica u crnoj boji na sivoj pozadini. Polovica problema bila je točna, a polovica netočna. Popis svih korištenih problema nalazi se u *Prilogu 9.4*.

Postupak

Postupak prezentacije numeričkih izraza, eksperimentalni zadatak, način odgovaranja te povratna informacija bili su identični kao i u eksperimentima sa zbrajanjem i oduzimanjem (Eksperiment 1 i Eksperiment 2).

4.7. Eksperiment 7

Nacrt istraživanja

U Eksperimentu 7 korišten je faktorski nacrt 2×2 s ponavljanim mjerenjima na oba faktora.

Nezavisne varijable bile su:

1. Sukladnost broja (da li brojnost objekata na slici odgovara broju spomenutom u rečenici) na dva nivoa: DA ili NE
2. Sukladnost oblika (da li objekt na slici odgovara pojmu spomenutom u rečenici) na dva nivoa: DA ili NE

Zavisne varijable su bile izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovao 48 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2010/2011), od čega 41 studentica i 7 studenata u rasponu dobi od 19 do 24 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađeno je s bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Identičan kao i u svim prethodnim eksperimentima.

Podražaji

Konstruirana je lista od 64 jednostavne tvrdnje tipa *tri psa*. Popis korištenih tvrdnji nalazi se u *Prilogu 9.5*. Pri tome, 32 tvrdnje uključivale su pojam koji je kasnije prikazan na slici (sukladnost oblika), a 32 tvrdnje uključivale su pojam koji ne odgovara objektu koji je kasnije prikazan na slici (nesukladnost oblika). Unutar svake liste, 16 tvrdnji je uključivalo broj koji odgovara brojnosti objekata koji su prikazani na slici (sukladnost broja) i 16 tvrdnji u kojima spomenuti broj ne odgovara brojnosti prikazanoj na slici (nesukladnost broja). Slike su preuzete iz standardizirane baze slika koju su napravili Rossion i Pourtois (2004). Ova baza nastala je tako da su na slikama iz starije baze skica objekata koju su konstruirali Snodgrass i Vanderwart (1980) dodane i boje i tekstura kako bi se olakšalo prepoznavanje. Brojevi koji se


spominju u tvrdnjama varirali su od jedan do četiri. Isto tako, brojnost objekata na slikama varirala je od jedan do četiri. Ovi brojevi i brojnosti su odabrani kako bi aktivirali sustav za subitizaciju odnosno za brzo prebrojavanje malih skupova. Za veće brojeve i brojnosti ne možemo očekivati preciznu individuaciju koja bi omogućila istraživanje veze između brojeva i brojnosti koju ti brojevi označavaju. Brojevi u tvrdnjama i brojnost na slikama balansirana je po uvjetima tako da se svaki broj i svaka brojnost pojavila jednak broj puta na svim nivoima faktorskog nacrtu.

t r i p s a

A)




B)



C)



D)



Slika 4.5. Nakon prezentacije tvrdnje kao što je *tri psa* uslijedila je prezentacija slike koja može pripadati jednoj od eksperimentalnih situacija: A) postoji i sukladnost oblika i sukladnost broja; B) postoji sukladnost oblika, ali nema sukladnosti broja; C) nema sukladnosti oblika, ali postoji sukladnost broja; D) nema niti sukladnosti oblika niti sukladnosti broja.

Postupak

Ispitivanje je provedeno u Laboratoriju za eksperimentalnu psihologiju na Filozofskom fakultetu u Rijeci, individualno sa svakim ispitanikom. Ispitanici su se udobno smjestili pred ekranom i položili kažiprst lijeve i desne ruke na uređaj za mjerenje vremena reakcije. Svaki pokušaj počinjao je s fiksacijskim znakom (X X X) koji je prikazan na sredini ekrana. Trajanje fiksacijskog znaka bilo je 300 ms nakon čega je prikazana tvrdnja (malim slovima; font arial; veličina 18). Tvrdnja je stajala na ekranu 1000 ms nakon čega je prikazan prazni ekran u trajanju od 100 ms, a nakon toga je uslijedila prezentacija slike. Slika se sastojala od jedne do četiri replikacije istog objekta poredane u istom redu i smještene na sredinu ekrana. Visina pojedine slike varirala je u rasponu od 2 do 3.5 cm, a širina u rasponu od 3 do 4.5 cm. Kada je bilo prezentirano četiri objekta, ukupna širina slike bila je 25 cm. Slika je ostala na ekranu sve dok ispitanik nije dao odgovor pritiskom na tipku na uređaju za mjerenje vremena reakcije.

Zadatak ispitanika je bio odrediti odgovara li pojam spomenut u tvrdnji objektu prikazanom na slici. Polovica ispitanika je odgovarala *da* s lijevom kažiprstom, a *ne* s desnom kažiprstom, a druga polovica ispitanika obrnuto. U uputi je ispitanicima dano do znanja da će tijekom eksperimenta broj u rečenici kao i brojnost objekata na slici također varirati, ali da mogu slobodno ignorirati tu činjenicu jer je irelevantna za zadatak. Također, u uputi je naglašeno da je potrebno odgovarati brzo, ali i točno. Nakon svakog pokušaja uslijedila je povratna informacija o točnosti odgovora na način da kada je ispitanik pogriješio prikazana je

riječ NETOČNO crvenom bojom u trajanju od 500 ms. Ako je ispitanik točno odgovorio, odmah se prelazilo na novi pokušaj. Prije glavnog mjerenja, ispitanicima je dano 8 pokušaja za vježbu da se priviknu na postupak. Nakon pokušaja za vježbu uslijedilo je 64 eksperimentalna pokušaja. Redoslijed zadavanja parova tvrdnja - slika bio je odabran po slučaju za svakog ispitanika.

4.8. Eksperiment 8

Nacrt istraživanja

U Eksperimentu 8 korišten je faktorski nacrt 2×2 s ponavljanim mjerenjima na oba faktora. Nezavisne varijable bile su:

1. Sukladnost broja (da li brojnost objekata na slici odgovara broju spomenutom u tvrdnji) na dva nivoa: DA ili NE
2. Sukladnost oblika (da li objekt na slici odgovara pojmu spomenutom u rečenici) na dva nivoa: DA ili NE

Zavisne varijable bile su izborno vrijeme reakcije mjereno u milisekundama i točnost odgovora iskazana kao postotak točnih odgovora.

Ispitanici

U eksperimentu je sudjelovalo 32 studenata preddiplomskog studija psihologije Filozofskog fakulteta u Rijeci (akademska godina 2011/2012), od čega 28 studentica i 4 studenata u rasponu dobi od 19 do 22 godina. Sudjelovanje u eksperimentu bilo je dobrovoljno, a nagrađeno je s bodovima za eksperimentalne sate. Ispitanici su potpisali pristanak za sudjelovanje u eksperimentu u kojem im je objašnjen postupak eksperimenta i eksperimentalni zadatak, rečeno predviđeno trajanje te zajamčena anonimnost podataka.

Pribor

Identičan kao i u svim prethodnim eksperimentima.

Podražaji

Umjesto jednostavnih tvrdnji (*tri psa*) u Eksperimentu 8 korištene su cjelovite rečenice kao što je *Tri psa lutala su ulicom*. Popis korištenih rečenica nalazi se u *Prilogu 9.6*.

Postupak


Identičan kao i u Eksperimentu 7.

5. REZULTATI

5.1. Eksperiment 1

Analiza vremena reakcije. Iz analize vremena reakcije isključeni su netočni odgovori (9.57 % podataka) kao i odgovori brži od 400 ms i sporiji od 4000 ms (0.22 % podataka), odnosno ekstremni odgovori za koje se može pretpostaviti da ne odražavaju vrijeme kognitivne obrade relevantne za istraživački problem te ih se može tretirati kao pogreške. Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama provedena je trosmjerna ($2 \times 2 \times 2$) analiza varijance s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), aritmetička operacija (zbrajanje ili oduzimanje) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,30) = .64$, $p = .429$, $\eta^2 = .02$, ali postoji glavni efekt operacije, $F(1,30) = 6.36$, $p = .017$, $\eta^2 = .17$ budući da su ispitanici brže rješavali zadatke oduzimanja ($M = 1011$ ms, $SE = 14.75$) nego zadatke zbrajanja ($M = 1044$ ms, $SE = 15.63$). Također, postoji i glavni efekt odgovora, $F(1,30) = 40.28$, $p < .001$, $\eta^2 = .57$ jer su ispitanici brže odgovarali kada je točan odgovor bio *da* ($M = 983$ ms, $SE = 14.52$) nego kada je točan odgovor bio *ne* ($M = 1072$ ms, $SE = 14.01$). Dvosmjerna interakcija između boje i operacije nije statistički značajna, $F(1,30) = 2.10$, $p = .158$, $\eta^2 = .07$, kao niti interakcija između boje i odgovora, $F(1,30) = 2.83$, $p = .103$, $\eta^2 = .09$, niti interakcija između operacije i odgovora, $F(1,30) = 2.31$, $p = .139$, $\eta^2 = .07$. Međutim, trosmjerna interakcija između boje, operacije i odgovora je statistički značajna, $F(1,30) = 16.90$, $p < .001$, $\eta^2 = .36$. Deskriptivni podaci za vrijeme reakcije za sve faktore prikazani su na slici 5.1.

Kako bi detaljnije istražili izvor trosmjerne interakcije provedena je analiza jednostavnih efekata pomoću multivarijatnog Pillai testa uz Holmovu korekciju za višestruko testiranje. U situaciji kada je točan odgovor bio *da*, ispitanici su bili za 114 ms brži u zadacima zbrajanja kada su bili prikazani u bijeloj nego u crnoj boji, $F(1,30) = 25.32$, $p < .001$. S druge strane, kod oduzimanja, ispitanici su bili brži za 101 ms kada su zadaci prikazani u crnoj nego u bijeloj boji, $F(1,30) = 12.10$, $p = .004$. Kada je točan odgovor bio *ne*, ispitanici su za 104 ms brže rješavali zbrajanje kada je zadatak bio prikazan u crnoj nego u bijeloj boji, $F(1,30) = 12.51$, $p = .004$. S druge strane, ispitanici su za 61 ms brže rješavali oduzimanje kada je zadatak bio prikazan u bijeloj nego u crnoj boji, $F(1,30) = 4.47$, $p = .043$.




Slika 5.1. Prosječno vrijeme reakcije (u sekundama) kada je točan odgovor Da (lijeva slika) i kada je točan odgovor Ne (desna slika) za aritmetičke zadatke zbrajanja i oduzimanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Analiza točnosti. Proporcije točnih odgovora za svaki uvjet su transformirane funkcijom arkus sinusa kako bi distribucije rezultata postale simetrične (Winer, 1971). Na transformiranim vrijednostima provedena je trosmjerna ($2 \times 2 \times 2$) ANOVA s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), aritmetička operacija (zbrajanje ili oduzimanje) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,30) < .01$, $p = .975$, $\eta^2 < .01$, aritmetičke operacije, $F(1,30) < .01$, $p = .996$, $\eta^2 < .01$, kao niti odgovora, $F(1,30) = .54$, $p = .467$, $\eta^2 = .02$. Dvosmjerna interakcija između boje i operacije nije statistički značajna, $F(1,30) = .10$, $p = .753$, $\eta^2 < .01$, kao niti interakcija između boje i odgovora, $F(1,30) = .58$, $p = .454$, $\eta^2 = .02$. Međutim, postoji statistički značajna interakcija operacija x odgovor, $F(1,30) = 13.19$, $p = .001$, $\eta^2 = .31$. Također, postoji statistički značajna trosmjerna interakcija boja x operacija x odgovor, $F(1,30) = 8.84$, $p = .006$, $\eta^2 = .23$. Deskriptivni podaci za točnost za sve faktore prikazani su na slici 5.2. Grafički prikaz napravljen je na osnovu netransformiranih proporcija.

Kako bi ispitali izvor trosmjerne interakcije i utvrdili je li došlo do trgovine između brzine i točnosti provedena je analiza jednostavnih efekata pomoću multivarijatnog Pillai testa uz Holmovu korekciju za višestruko testiranje. Analiza je pokazala da kada je točan odgovor *da*, ne postoji razlika u točnosti između prezentacije u bijeloj i crnoj boji za zbrajanje, $F(1,30)$

= 1.08, $p = .852$, kao niti za oduzimanje, $F(1,30) = 3.31$, $p = .315$. Također, kada je točan odgovor *ne*, nema razlike u točnosti između prezentacije zadataka u bijeloj i crnoj boji za zbrajanje, $F(1,30) = .56$, $p = .852$, kao niti za oduzimanje, $F(1,30) = 1.19$, $p = .852$. Iz toga se može zaključiti da nije došlo do trgovine između brzine i točnosti jer kod svih relevantnih usporedbi, kraće vrijeme reakcije nije praćeno i manjom točnošću. Dodatnu potvrdu za ovaj zaključak daje i činjenica da nema statistički značajne korelacije između vremena reakcije i proporcije točnih odgovora, $r = -.07$, $t(246) = -1.16$, $p = .248$.




Slika 5.2. Prosječna točnost (u postocima) kada je točan odgovor Da (lijeva slika) i kada je točan odgovor Ne (desna slika) za aritmetičke zadatke zbrajanja i oduzimanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.2. Eksperiment 2

Analiza vremena reakcije. Iz analize vremena reakcije isključeni su netočni odgovori (6.81 % podataka) kao i odgovori brži od 400 ms i sporiji od 4000 ms (0.97 % podataka). Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama je provedena trosmjerna ($2 \times 2 \times 2$) analiza varijance s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), aritmetička operacija (zbrajanje ili oduzimanje) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,29) = .04, p = .839, \eta^2 < .01$, ali postoji glavni efekt operacije, $F(1,29) = 57.15, p < .001, \eta^2 = .66$, budući da su ispitanici brže rješavali zadatke oduzimanja ($M = 1468$ ms, $SE = 18.09$) nego zadatke zbrajanja ($M = 1585$ ms, $SE = 18.30$). Također, postoji i glavni efekt odgovora, $F(1,29) = 65.89, p < .001, \eta^2 = .69$, jer su ispitanici brže odgovarali kada je točan odgovor bio *da* ($M = 1467$ ms, $SE = 18.37$) nego kada je točan odgovor bio *ne* ($M = 1586$ ms, $SE = 17.91$). Dvosmjerna interakcija između boje i operacije nije statistički značajna, $F(1,29) = 3.62, p = .067, \eta^2 = .11$, kao niti interakcija između operacije i odgovora, $F(1,29) = .08, p = .781, \eta^2 < .01$. Dvosmjerna interakcija između boje i odgovora je statistički značajna, $F(1,29) = 5.39, p = .027, \eta^2 = .16$. Međutim, analiza jednostavnih efekata za ovu dvosmjernu interakciju nije pokazala statistički značajnu razliku u brzini odgovora između bijele ($M = 1454$ ms, $SE = 12.92$) i crne ($M = 1479$ ms, $SE = 27.08$) boje kada je točan odgovor bio *da*, $F(1,29) = 2.07, p = .303$. Isto tako, nema razlike između bijele ($M = 1602$ ms, $SE = 23.35$) i crne ($M = 1571$ ms, $SE = 17.49$) boje kada je točan odgovor bio *ne*, $F(1,29) = 2.17, p = .303$. Replicirajući najvažniji nalaz iz Eksperimenta 1, pokazalo se da i u Eksperimentu 2 postoji statistički značajna trosmjerna interakcija između boje, operacije i odgovora, $F(1,29) = 59.59, p < .001, \eta^2 = .67$. Deskriptivni podaci za vrijeme reakcije za sve faktore prikazani su na slici 5.3.


Analiza jednostavnih efekata pokazala je da su u situaciji kada je točan odgovor bio *da*, ispitanici bili za 190 ms brži u zadacima zbrajanja kada su bili prikazani u bijeloj nego u crnoj boji, $F(1,29) = 49.06, p < .001$. S druge strane, kod oduzimanja, ispitanici su bili za 140 ms brži kada su zadaci prikazani u crnoj nego u bijeloj boji, $F(1,29) = 37.97, p < .001$. Kada je točan odgovor bio *ne*, ispitanici su za 149 ms brže rješavali zbrajanje kada je zadatak bio prikazan u crnoj nego u bijeloj boji, $F(1,29) = 38.28, p < .001$. S druge strane, ispitanici su za 87 ms brže rješavali oduzimanje kada je zadatak bio prikazan u bijeloj nego u crnoj boji, $F(1,29) = 4.69, p = .039$.



Slika 5.3. Prosječno vrijeme reakcije (u sekundama) kada je točan odgovor Da (lijeva slika) i kada je točan odgovor Ne (desna slika) za aritmetičke zadatke zbrajanja i oduzimanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Analiza točnosti. Na transformiranim vrijednostima provedena je trosmjerna ($2 \times 2 \times 2$) ANOVA s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), aritmetička operacija (zbrajanje ili oduzimanje) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,29) = .29$, $p = .594$, $\eta^2 = .01$ niti aritmetičke operacije, $F(1,29) = .08$, $p = .781$, $\eta^2 < .01$, ali postoji značajan glavni efekt odgovora, $F(1,29) = 7.90$, $p = .009$, $\eta^2 = .21$ zato jer su ispitanici bili točniji kada je trebalo dati odgovor *ne* ($M = 93.24$, $SE = .71$) nego kada je trebalo dati odgovor *da* ($M = 91.20$ %, $SE = .82$). Dvosmjerna interakcija između boje i operacije nije statistički značajna, $F(1,29) < .01$, $p = .979$, $\eta^2 < .01$, kao i niti interakcija između operacije i odgovora, $F(1,29) = 1.76$, $p = .195$, $\eta^2 = .06$. Kao i kod vremena reakcije, i kod točnosti postoji značajna interakcija boja x odgovor, $F(1,29) = 12.07$, $p = .002$, $\eta^2 = .29$. Analiza jednostavnih efekata pokazuje da za odgovor *da* nema razlike u točnosti kada je problem prikazan u bijeloj ($M = 91.67$ %, $SE = 1.02$) ili u crnoj boji ($M = 90.74$ %, $SE = .88$), $F(1,29) = 2.04$, $p = .164$. S druge strane za odgovor *ne*, ispitanici su bili točniji kada je problem prikazan u crnoj ($M = 94.35$ %, $SE = .68$) nego u bijeloj boji ($M = 92.13$ %, $SE = .91$), $F(1,29) = 7.94$, $p = .017$. Međutim, ne postoji trosmjerna interakcija između boje operacije i odgovora, $F(1,29) = 1.18$, $p = .286$, $\eta^2 = .04$. Iz toga se može zaključiti da nije došlo do trgovine između brzine i točnosti što potvrđuje i podatak da nema


statistički značajne korelacije između vremena reakcije i proporcije točnih odgovora, $r = -.08$, $t(238) = -1.31$, $p = .192$. Deskriptivni podaci za točnost za sve faktore prikazani su na slici 5.4.



Slika 5.4. Prosječna točnost (u postocima) kada je točan odgovor Da (lijeva slika) i kada je točan odgovor Ne (desna slika) za aritmetičke zadatke zbrajanja i oduzimanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.3. Eksperiment 3

Analiza vremena reakcije. Iz analize vremena reakcije su isključeni netočni odgovori (3.96 % podataka) kao i odgovori brži od 300 ms i sporiji od 1000 ms (1.79 % podataka). Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama je provedena trosmjerna ($2 \times 2 \times 2$) analiza varijance s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), predznak (plus ili minus) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,44) = .83$, $p = .367$, $\eta^2 = .02$, niti glavni efekt odgovora, $F(1,44) = 2.38$, $p = .130$, $\eta^2 = .056$, ali postoji glavni efekt predznaka, $F(1,44) = 11.64$, $p = .001$, $\eta^2 = .21$ zato jer su ispitanici brže odgovarali na pozitivne ($M = 496$ ms, $SE = 3.14$), nego na negativne brojeve ($M = 506$ ms, $SE = 2.86$). Dvosmjerna interakcija između boje i predznaka nije statistički značajna, $F(1,44) = 1.30$, $p = .261$, $\eta^2 = .03$, kao niti interakcija između boje i odgovora, $F(1,44) = 1.41$, $p = .242$, $\eta^2 = .03$. Dvosmjerna interakcija između predznaka i odgovora je statistički značajna, $F(1,44) = 50.26$, $p < .001$, $\eta^2 = .53$. Međutim, trosmjerna interakcija između boje, operacije i odgovora nije statistički značajna, $F(1,44) = .67$, $p = .416$, $\eta^2 = .02$.




Slika 5.5. Prosječno vrijeme reakcije (u sekundama) kada je točan odgovor Da (lijeva slika) i kada je točan odgovor Ne (desna slika) za određivanje pariteta pozitivnih i negativnih brojeva kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Analiza jednostavnih efekata za dvosmjernu interakciju između predznaka i odgovora pokazala je da su kod odgovora *da*, ispitanici za 33 ms brže reagirali kada je bio prezentiran pozitivan broj ($M = 481$ ms, $SE = 3.12$), nego kada je prezentiran negativan broj ($M = 514$ ms, $SE = 3.11$), $F(1,44) = 54.39$, $p < .001$. S druge strane, kod odgovora *ne*, ispitanici su bili za 13 ms sporiji kada je bio prezentiran pozitivan broj ($M = 510$ ms, $SE = 3.18$), nego kada je bio prezentiran negativan broj ($M = 497$ ms, $SE = 3.16$), $F(1,44) = 9.31$, $p = .004$. Deskriptivni podaci za vrijeme reakcije za sve faktore prikazani su na slici 5.5.

Analiza točnosti. Na transformiranim vrijednostima provedena je trosmjerna ($2 \times 2 \times 2$) ANOVA s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), predznak (plus ili minus) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,44) = 3.26$, $p = .078$, $\eta^2 = .07$, predznaka, $F(1,44) = 1.61$, $p = .211$, $\eta^2 = .04$, kao niti značajan glavni efekt odgovora, $F(1,44) = .08$, $p = .783$, $\eta^2 < .01$. Dvosmjerna interakcija između boje i predznaka nije statistički značajna, $F(1,44) = .07$, $p = .797$, $\eta^2 < .01$, kao niti interakcija između boje i odgovora, $F(1,44) = .47$, $p = .496$, $\eta^2 = .01$. Kao i kod vremena reakcije, i kod točnosti postoji značajna interakcija predznak x odgovor, $F(1,44) = 10.48$, $p = .002$, $\eta^2 = .19$. Analiza jednostavnih efekata je pokazala da su ispitanici bili točniji za pozitivne ($M = 95.78$ %, $SE = .59$), nego za negativne brojeve ($M = 92.78$ %, $SE = .73$) kada je točan odgovor bio *da*, $F(1,44) = 8.00$, $p = .014$. Kada je točan odgovor bio *ne*, nije bilo razlike u točnosti između pozitivnih ($M = 93.72$ %, $SE = .57$) i negativnih brojeva ($M = 94.72$ %, $SE = .57$), $F(1,44) = 2.09$, $p = .156$.


Također, postoji statistički značajna trosmjerna interakcija između boje, predznaka i odgovora, $F(1,44) = 4.05$, $p = .050$, $\eta^2 = .08$. Analiza jednostavnih efekata je pokazala da u situaciji kada je točan odgovor bio *da*, nije bilo razlike u točnosti kada su ispitanici određivali paritet pozitivnih brojeva prikazanih u bijeloj i u crnoj boji, $F(1,44) = .17$, $p = 1.00$. Također, kod određivanja pariteta negativnih brojeva, nije bilo razlike u točnosti kada su brojevi prikazani u crnoj ili u bijeloj boji, $F(1,44) = 3.07$, $p = .348$. Isto tako, kada je točan odgovor bio *ne*, nije bilo razlike u točnosti određivanja pariteta za pozitivne brojeve kada su prikazani u crnoj ili u bijeloj boji, $F(1,44) = 2.84$, $p = .348$. Na kraju, niti za negativne brojeve, nije bilo razlike u točnosti kada su prikazani u bijeloj ili u crnoj boji, $F(1,44) = .41$, $p = 1.00$. Na kraju možemo navesti da postoji statistički značajna negativna korelacija između vremena reakcije i proporcije točnih odgovora, $r = -.19$, $t(358) = -3.66$, $p < .001$. Deskriptivni podaci za točnost za sve faktore prikazani su na slici 5.6.



Slika 5.6. Prosječna točnost (u postocima) kada je točan odgovor Da (lijeva slika) i kada je točan odgovor Ne (desna slika) za određivanje pariteta pozitivnih i negativnih brojeva kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.4. Eksperiment 4


Analiza vremena reakcije. Iz analize vremena reakcije su isključeni netočni odgovori (6.34 % podataka) kao i odgovori brži od 400 ms i sporiji od 4000 ms (0.05 % podataka). Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama je provedena dvosmjerna (2×2) analiza varijance s ponavljanim mjerenjima na faktorima boja (crno ili bijelo) i odgovor (da ili ne). ANOVA je pokazala da postoji statistički značajan glavni efekt boje, $F(1,29) = 13.68$, $p < .001$, $\eta^2 = .32$, zato jer su ispitanici brže reagirali na crnu ($M = 985$ ms, $SE = 13.06$), nego na bijelu boju ($M = 1011$ ms, $SE = 15.54$). Također, postoji i glavni efekt odgovora, $F(1,29) = 81.62$, $p < .001$, $\eta^2 = .74$, zato jer su ispitanici brže odgovarali kada je točan dogovor bio *da* ($M = 937$ ms, $SE = 8.53$) nego kada je točan odgovor bio *ne* ($M = 1059$ ms, $SE = 9.79$). Međutim, ne postoji statistički značajna interakcija između boje i odgovora, $F(1,29) = 2.33$, $p = .138$, $\eta^2 = .07$. Deskriptivni podaci za vrijeme reakcije prikazani su na slici 5.7.



Slika 5.7. Prosječno vrijeme reakcije (u sekundama) kada je točan odgovor Da i kada je točan odgovor Ne za aritmetičke zadatke zbrajanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Analiza točnosti. Na transformiranim vrijednostima provedena je dvosmjerna (2×2) ANOVA s ponavljanim mjerenjima na faktorima boja (crno ili bijelo) i odgovor (da ili ne).


ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,29) = .08$, $p = .777$, $\eta^2 < .01$ i odgovora, $F(1,29) = 2.19$, $p = .150$, $\eta^2 = .07$. Također, ne postoji interakcija između boje i odgovora, $F(1,29) = 3.06$, $p = .091$, $\eta^2 = .10$. Analiza jednostavnih efekata pokazuje da nema razlike u točnosti između prezentacije problema u bijeloj i crnoj boji niti za odgovor *da* ($M_{bijelo} - M_{crno} = 1.02\%$), $F(1,29) = 1.20$, $p = .566$, niti za odgovor *ne* ($M_{bijelo} - M_{crno} = -.64\%$), $F(1,29) = .82$, $p = .566$. Dodatna analiza pokazuje da postoji statistički značajna pozitivna korelacija između vremena reakcije i točnosti, $r = .20$, $t(118) = 2.24$, $p = .027$, što upućuje na pojavu trgovine između brzine i točnosti zbog čega je potreban dodatan oprez pri interpretaciji rezultata. Deskriptivni podaci za točnost prikazani su na slici 5.8.



Slika 5.8. Prosječna točnost (u postocima) kada je točan odgovor Da i kada je točan odgovor Ne za aritmetičke zadatke zbrajanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Zajednička analiza vremena reakcije i točnosti. Kako bi uklonili utjecaj trgovine između brzine i točnosti na analizu rezultata, kreirana je nova kompozitna varijabla koja se zove inverzna procesna efikasnost (Townsend i Ashby, 1978; 1983). Ona se definira kao prosječna energija koju sustav troši dok obrađuje informacije odnosno snaga sustava. Izračunava se tako da vrijeme reakcije podijelimo s proporcijom točnih odgovora za svakog ispitanika u svakom uvjetu. Mjerna jedinica kompozitne varijable opet je vrijeme izraženo u milisekundama ili sekundama budući da proporcije nemaju mjernu jedinicu. S inverznom


procesnom efikasnošću kao zavisnom varijablom, provedena je ANOVA s ponovljenim mjerenjima na faktorima boja (crno ili bijelo) i odgovor (da ili ne). ANOVA je pokazala da postoji statistički značajan glavni efekt boje, $F(1,29) = 7.75$, $p = .009$, $\eta^2 = .21$, budući da su ispitanici brže reagirali na crnu ($M = 1054$ ms, $SE = 16.35$), nego na bijelu boju ($M = 1078$ ms, $SE = 19.75$). Također, postoji i glavni efekt odgovora, $F(1,29) = 50.14$, $p < .001$, $\eta^2 = .63$, budući da su ispitanici brže davali odgovore *da* ($M = 994$ ms, $SE = 12.34$) nego odgovore *ne* ($M = 1138$ ms, $SE = 12.69$). Također, postoji i dvosmjerna interakcija između boje i odgovora, $F(1,29) = 4.54$, $p = .042$, $\eta^2 = .14$. Analiza jednostavnih efekata pokazala je da kada je točan odgovor *da*, nema razlike u brzini između prezentacije problema u bijeloj i crnoj boji ($M_{bijelo} - M_{crno} = 1$ ms), $F(1,29) < .01$, $p = .963$. S druge strane, kada je točan odgovor *ne*, ispitanici su pokazali za 46 ms brži odgovor kada je problem prikazan u crnoj nego u bijeloj boji, $F(1,29) = 12.83$, $p = .002$. Deskriptivni podaci za inverznu procesnu efikasnost za oba faktora prikazani su na slici 5.9.



Slika 5.9. Prosječna inverzna procesna efikasnost (u sekundama) kada je točan odgovor *Da* i kada je točan odgovor *Ne* za zadatke zbrajanja koji su prikazani u bijelom (bijeli stupci) i crnom fontu (sivi stupci). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.


5.5. Eksperiment 5

Analiza vremena reakcije. Iz analize vremena reakcije isključeni su netočni odgovori (7.45 % podataka), kao i odgovori brži od 400 ms i sporiji od 4000 ms (0.22 % podataka). Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama provedena je dvosmjerna (2×2) analiza varijance s ponavljanim mjerenjima na faktorima boja (crno ili bijelo) i odgovor (da ili ne). ANOVA je pokazala da postoji statistički značajan glavni efekt boje, $F(1,25) = 4.30$, $p = .049$, $\eta^2 = .15$, budući da su ispitanici brže reagirali na crnu ($M = 1145$ ms, $SE = 13.27$) nego na bijelu boju ($M = 1168$ ms, $SE = 10.47$). Također, postoji i glavni efekt odgovora, $F(1,25) = 20.91$, $p < .001$, $\eta^2 = .46$ budući da su ispitanici brže odgovarali kada je točan odgovor *ne* ($M = 1126$ ms, $SE = 12.25$) nego kada je točan odgovor *da* ($M = 1188$ ms, $SE = 8.43$). Također, postoji statistički značajna interakcija između boje i odgovora, $F(1,25) = 11.85$, $p = .002$, $\eta^2 = .32$. Analiza jednostavnih efekata pokazala je da kada je točan odgovor *da*, nema razlike u brzini odgovora između prezentacije problema u bijeloj i crnoj boji ($M_{bijelo} - M_{crno} = -9$ ms), $F(1,25) = .75$, $p = .395$. S druge strane, kada je točan odgovor *ne*, ispitanici su bili za 55 ms brži kada je problem prikazan u crnoj nego u bijeloj boji, $F(1,25) = 9.62$, $p = .009$. Deskriptivni podaci za vrijeme reakcije prikazani su na slici 5.10.



Slika 5.10. Prosječno vrijeme reakcije (u sekundama) kada je točan odgovor *Da* i kada je točan odgovor *Ne* za aritmetičke zadatke oduzimanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.


Analiza točnosti. Na transformiranim vrijednostima provedena je dvosmjerna (2×2) ANOVA s ponavljanim mjerenjima na faktorima boja (crno ili bijelo) i odgovor (da ili ne). ANOVA je pokazala da postoji statistički značajan glavni efekt boje, $F(1,25) = 7.35$ $p = .012$, $\eta^2 = .23$, jer su ispitanici točniji kada je problem prikazan u crnoj ($M = 93.38\%$, $SE = .64$) nego u bijeloj boji ($M = 91.29\%$, $SE = .78$). Nadalje, nema glavnog efekta predznaka, $F(1,25) = 2.17$, $p = .153$, $\eta^2 = .08$. Međutim, postoji interakcija između boje i odgovora, $F(1,25) = 4.91$, $p = .036$, $\eta^2 = .16$. Analiza jednostavnih efekata pokazuje da nema razlike u točnosti između prezentacije problema u bijeloj i crnoj boji za odgovor *da* ($M_{bijelo} - M_{crno} = -.75\%$), $F(1,25) = .53$, $p = .475$. Međutim, za odgovor *ne*, ispitanici su pokazali za 3.42 % veću točnost kada je problem prikazan u crnoj nego u bijeloj boji, $F(1,25) = 14.41$, $p = .002$. Dodatna analiza pokazuje da nema korelacije između vremena reakcije i točnosti, $r = -.03$, $t(102) = -.26$, $p = .793$. Deskriptivni podaci za točnost prikazani su na slici 5.11.



Slika 5.11. Prosječna točnost (u postocima) kada je točan odgovor Da i kada je točan odgovor Ne za aritmetičke zadatke oduzimanja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Zajednička analiza vremena reakcije i točnosti. Radi lakše usporedbe rezultata Eksperimenta 4 i 5, i za podatke iz Eksperimenta 5 provedena je zajednička analiza vremena reakcije i točnosti tako da je kreirana kompozitna varijabla inverzne procesne efikasnosti. S inverznom procesnom efikasnošću kao zavisnom varijablom, provedena je ANOVA s

ponovljenim mjerenjima na faktorima boja (crno ili bijelo) i odgovor (da ili ne). ANOVA je pokazala da postoji statistički značajan glavni efekt boje, $F(1,25) = 13.83$, $p = .001$, $\eta^2 = .36$, jer su ispitanici bili brži za crnu ($M = 1234$ ms, $SE = 17.94$) nego za bijelu boju ($M = 1289$ ms, $SE = 17.53$). Također, postoji i glavni efekt odgovora, $F(1,25) = 17.15$, $p < .001$, $\eta^2 = .41$, budući da su ispitanici bili brži za odgovor *ne* ($M = 1219$ ms, $SE = 18.26$) nego za odgovor *da* ($M = 1304$ ms, $SE = 14.46$). Također, postoji i dvosmjerna interakcija između boje i odgovora, $F(1,25) = 11.49$, $p = .002$, $\eta^2 = .31$. Analiza jednostavnih efekata pokazala je da kada je točan odgovor *da*, nema razlike u procesnoj efikasnosti između prezentacije problema u bijeloj i crnoj boji ($M_{bijelo} - M_{crno} = 2$ ms), $F(1,25) = .01$, $p = .916$. S druge strane, kada je točan odgovor *ne*, ispitanici su bili za 106 ms brži kada je problem prikazan u crnoj nego u bijeloj boji, $F(1,25) = 23.76$, $p < .001$. Deskriptivni podaci za inverznu procesnu efikasnost za oba faktora su prikazani na slici 5.12.



Slika 5.12. Prosječna inverzna procesna efikasnost (u sekundama) kada je točan odgovor *Da* i kada je točan odgovor *Ne* za zadatke oduzimanja koji su prikazani u bijelom (bijeli stupci) i crnom fontu (sivi stupci). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.6. Eksperiment 6

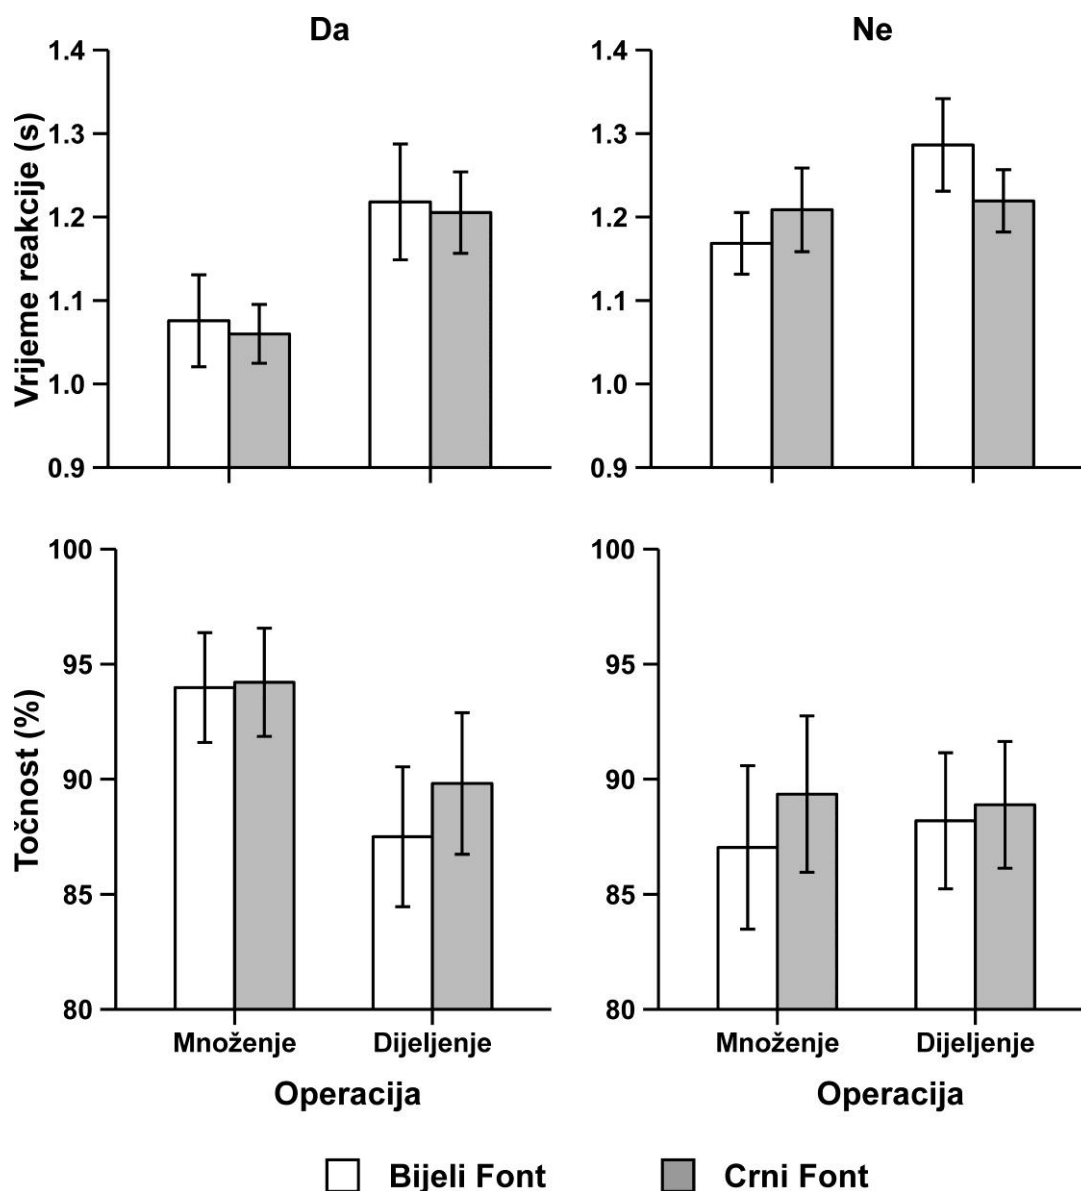
Analiza vremena reakcije. Iz analize vremena reakcije su isključeni netočni odgovori (9.61% podataka) kao i odgovori brži od 400 ms i sporiji od 4000 ms (0.52 % podataka). Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama provedena je trosmjerna ($2 \times 2 \times 2$) analiza varijance s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), aritmetička operacija (množenje ili dijeljenje) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,23) = 1.15$, $p = .295$, $\eta^2 = .05$, ali postoji glavni efekt operacije, $F(1,23) = 31.74$, $p < .001$, $\eta^2 = .58$, jer su ispitanici brže rješavali zadatke množenja ($M = 1128$ ms, $SE = 17.07$) nego dijeljenja ($M = 1232$ ms, $SE = 17.17$). Također, postoji i glavni efekt odgovora, $F(1,23) = 24.74$, $p < .001$, $\eta^2 = .52$, jer su ispitanici brže reagirali kada je točan odgovor bio *da* ($M = 1140$ ms, $SE = 19.62$) nego kada je točan odgovor bio *ne* ($M = 1221$ ms, $SE = 15.71$). Dvosmjerna interakcija između boje i operacije nije statistički značajna, $F(1,23) = 2.77$, $p = .110$, $\eta^2 = .11$ kao niti interakcija između boje i odgovora, $F(1,23) < .01$, $p = .981$, $\eta^2 < .01$. Dvosmjerna interakcija između operacije i odgovora je statistički značajna, $F(1,23) = 4.34$, $p = .049$, $\eta^2 = .16$. Nadalje, ne postoji statistički značajna trosmjerna interakcija između boje, operacije i odgovora, $F(1,23) = 2.15$, $p = .156$, $\eta^2 = .09$.

Kako bi detaljnije istražili izvor dvosmjerne interakcije između operacije i odgovora provedena je analiza jednostavnih efekata. Ona je pokazala da u situaciji kada je točan odgovor bio *da*, ispitanici su bili za 144 ms brži kod verificiranja zadataka množenja nego dijeljenja, $F(1,23) = 26.68$, $p < .001$. Kod odgovora *ne*, ispitanici su opet bili brži kod verificiranja zadataka množenja u odnosu na dijeljenje, ali je taj efekt bio nešto manji odnosno 64 ms, $F(1,23) = 6.49$, $p = .018$.

Analiza točnosti. Na transformiranim vrijednostima provedena je trosmjerna ($2 \times 2 \times 2$) ANOVA s ponavljanim mjerenjima na faktorima boja (crno ili bijelo), aritmetička operacija (zbrajanje ili oduzimanje) i odgovor (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt boje, $F(1,23) = 1.52$, $p = .230$, $\eta^2 = .06$, ali postoji glavni efekt aritmetičke operacije, $F(1,23) = 8.64$, $p = .007$, $\eta^2 = .27$, budući da su ispitanici bili točniji u zadacima množenja ($M = 91.15$ %, $SE = 1.04$) nego u zadacima dijeljenja ($M = 88.60$ %, $SE = .94$). Također, postoji i značajan glavni efekt odgovora, $F(1,23) = 10.01$, $p = .004$, $\eta^2 = .30$, budući da su ispitanici točniji kada daju odgovor *da* ($M = 91.38$ %, $SE = .96$) nego kada daju odgovor *ne* ($M = 88.37$ %, $SE = 1.00$). Dvosmjerna interakcija između boje i operacije nije značajna, $F(1,23) = .39$, $p = .537$, $\eta^2 = .02$, kao ni interakcija između boje i odgovora, $F(1,23)$

= .02, $p = .882$, $\eta^2 < .01$. Kao i kod vremena reakcije, i kod točnosti postoji značajna interakcija operacija x odgovor, $F(1,23) = 9.47$, $p = .005$, $\eta^2 = .29$. Međutim, ne postoji trosmjerna interakcija između boje operacije i odgovora, $F(1,23) = .38$, $p = .156$, $\eta^2 = .04$.

Analiza jednostavnih efekata za dvosmjernu interakciju između operacije i odgovora pokazala je da kada je točan odgovor *da*, ispitanici su bili za 5.4 % točniji kada su rješavali zadatke množenja u odnosu na zadatke dijeljenja, $F(1,23) = 22.77$, $p < .001$. S druge strane, kada je točan odgovor bio *ne*, nije bilo statistički značajne razlike u točnosti verificiranja između zadataka množenja i dijeljenja ($M_{množenje} - M_{dijeljenje} = .35\%$), $F(1,23) = .05$, $p = .826$. Dodatna analiza pokazuje da je korelacija između vremena reakcije i točnosti negativna i statistički značajna, $r = -.16$, $t(190) = -2.20$, $p = .029$. Deskriptivni podaci za vrijeme reakcije i točnost za sve faktore prikazani su na slici 5.13.




Slika 5.13. Prosječno vrijeme reakcije (u sekundama; gornji red) i prosječna točnost odgovora (u postocima; donji red) kada je točan odgovor Da (lijevi stupac) i kada je točan odgovor Ne (desni stupac) za aritmetičke zadatke množenja i dijeljenja kada su prikazani u bijeloj (bijeli stupac) ili u crnoj boji (sivi stupac). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.7. Eksperiment 7

S obzirom da su u 7. i 8. eksperimentu korištene riječi kao podražaji potrebno je napraviti zasebnu analizu po ispitanicima i po riječima (ili rečenicama). Razlog tome je činjenica da su odabrane riječi samo mali dio skupa svih riječi odnosno podražaja koji se mogu javiti u nekom jeziku. Stoga je potrebno statističkom analizom provjeriti mogu li se rezultati dobiveni s odabranim skupom riječi generalizirati na druge riječi koje nisu upotrijebljene u eksperimentu. U tu svrhu potrebno je napraviti zasebnu analizu u kojem se riječi tretiraju kao ispitanici odnosno izračunaju se prosječna vremena reakcije za svaku riječ po ispitanicima. Ako se rezultati analize po riječima podudaraju s rezultatima analize po ispitanicima tada s većom sigurnošću možemo tvrditi da efekt stvarno postoji jer se može generalizirati i po ispitanicima i po podražajima.


5.7.1. Analiza po ispitanicima

Analiza vremena reakcije. Iz analize vremena reakcije su isključeni netočni odgovori (3.72% podataka) kao i odgovori jednog ispitanika koji je pokazao nisku razinu točnosti ($< 85\%$) dok su svi ostali ispitanici pokazali točnost $> 90\%$. Također, postavili smo granicu za ekstremne odgovore tako da bi trebalo ukloniti odgovore koji su brži od 300 ms i sporiji od 3000 ms, ali nije bilo takvih odgovora. Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama provedena je dvosmjerna (2×2) analiza varijance s ponavljanim mjerenjima na faktorima sukladnost broja (da ili ne) i sukladnost oblika (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,46) = 2.16$, $p = .148$, $\eta^2 = .04$, ali postoji glavni efekt sukladnosti broja, $F(1,46) = 11.79$, $p = .001$, $\eta^2 = .20$, budući da su ispitanici bili brži kada je postojala sukladnost broja ($M = 544$ ms, $SE = 6.87$) nego u situaciji kada nije bilo sukladnosti broja ($M = 569$ ms, $SE = 7.61$). Dvosmjerna interakcija između sukladnosti oblika i sukladnosti broja je statistički značajna, $F(1,46) = 7.42$, $p = .009$, $\eta^2 = .14$. Analiza jednostavnih efekata pokazala je da kada je trebalo dati *da* odgovor, odnosno kada su oblici bili sukladni, ispitanici su bili za 46 ms brži kada je postojala i sukladnost broja nego kada nije bilo sukladnosti broja, $F(1,46) = 16.51$, $p < .001$. S druge strane, kada je trebalo dati *ne* odgovor, odnosno kada nije bilo sukladnosti oblika, nije bilo razlike između situacije kada je postojala sukladnost broja i kada nije bilo sukladnosti broja ($M_{da} - M_{ne} = -2$ ms), $F(1,46) = .08$, $p = .778$. Deskriptivni podaci za vrijeme reakcije za oba faktora prikazani su na slici 5.14.



Slika 5.14. Prosječno vrijeme reakcije (u sekundama) kada je postojala sukladnost pojma i oblika (lijevo) i kada nije (desno) te kada je postojala sukladnost broja i brojnosti (bijeli stupci) i kada nije (sivi stupci). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Analiza točnosti. Analiza točnosti provedena je na isti način kao i u prethodnim analizama odnosno na proporcijama točnih odgovora primijenjena je arkus sinus transformacija. Na transformiranim vrijednostima provedena je dvosmjerna (2×2) ANOVA s ponavljanim mjerenjima na faktorima sukladnost broja (da ili ne) i sukladnost oblika (da ili ne). ANOVA je pokazala da ne postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,46) = 2.22$, $p = .143$, $\eta^2 = .05$, ne postoji glavni efekt sukladnosti broja, $F(1,46) = .31$, $p = .578$, $\eta^2 < .01$, a nema niti interakcije između sukladnosti oblika i sukladnosti broja, $F(1,46) = 1.05$, $p = .310$, $\eta^2 = .02$. U svim uvjetima točnost je vrlo visoka te možemo zaključiti da nije došlo do trgovine između brzine i točnosti odnosno da se razlike dobivene s vremenom reakcije mogu pripisati djelovanju sukladnosti broja, a ne promjenama u strategiji odgovaranja ispitanika. Deskriptivni podaci za točnost za oba faktora prikazani su na slici 5.15.



Slika 5.15. Prosječna točnost odgovora (u postocima) kada je postojala sukladnost pojma i oblika (lijevo) i kada nije (desno) te kada je postojala sukladnost broja i brojnosti (bijeli stupci) i kada nije (sivi stupci). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.7.2. Analiza po riječima

Analiza vremena reakcije. Identična analiza opisana u prethodnim poglavljima primijenjena je i u analizi po riječima. ANOVA je pokazala da ne postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,60) = 3.19$, $p = .079$, $\eta^2 = .05$, ali postoji glavni efekt sukladnosti broja, $F(1,60) = 5.57$, $p = .022$, $\eta^2 = .08$. Dvosmjerna interakcija između sukladnosti oblika i sukladnosti broja je na granici statističke značajnosti, $F(1,60) = 3.86$, $p = .054$, $\eta^2 = .06$. Analiza jednostavnih efekata je pokazala da kada je trebalo dati *da* odgovor, odnosno kada su oblici bili sukladni, ispitanici su bili statistički značajno brži kada je postojala i sukladnost broja nego kada nije bilo sukladnosti broja, $F(1,60) = 9.35$, $p = .007$. S druge strane, kada je trebalo dati *ne* odgovor, odnosno kada nije bilo sukladnosti oblika, nije bilo razlike između situacije kada je postojala sukladnost broja i kada nije bilo sukladnosti broja, $F(1,60) = .08$, $p = .782$. Na taj način, u analizi po riječima, repliciran je glavni nalaz iz analize po ispitanicima da sukladnost broja interferira s izvođenjem zadatka utvrđivanja sukladnosti oblika iako je sukladnost broja irelevantna za ovaj zadatak.

Analiza točnosti. ANOVA je pokazala da ne postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,60) = 3.12$, $p = .082$, $\eta^2 = .05$, ne postoji glavni efekt sukladnosti broja, $F(1,60) = 1.05$, $p = .309$, $\eta^2 = .02$, a nema niti interakcije između sukladnosti oblika i


sukladnosti broja, $F(1,60) = .99$, $p = .325$, $\eta^2 = .02$. U svim uvjetima točnost je vrlo visoka te možemo zaključiti da nije došlo do trgovine između brzine i točnosti.

5.8. Eksperiment 8

5.8.1. Analiza po ispitanicima


Analiza vremena reakcije. Iz analize vremena reakcije isključeni su netočni odgovori (1.41% podataka) kao i odgovori brži od 300 ms i sporiji od 3000 ms (0.05 % podataka). Na preostalim podacima izračunate su aritmetičke sredine za svakog ispitanika po svakom uvjetu. Na aritmetičkim sredinama provedena je dvosmjerna (2×2) analiza varijance s ponavljanim mjerenjima na faktorima sukladnost broja (da ili ne) i sukladnost oblika (da ili ne).

ANOVA je pokazala da ne postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,27) = .01$, $p = .968$, $\eta^2 < .01$, ali postoji glavni efekt sukladnosti broja, $F(1,27) = 6.49$, $p = .017$, $\eta^2 = .19$, budući da su ispitanici bili brži kada je postojala sukladnost broja ($M = 562$ ms, $SE = 6.94$) nego kada nije bilo sukladnosti broja ($M = 576$ ms, $SE = 7.87$). Dvosmjerna interakcija između sukladnosti oblika i sukladnosti broja je statistički značajna, $F(1,27) = 8.02$, $p = .009$, $\eta^2 = .23$. Analiza jednostavnih efekata je pokazala da kada je trebalo dati *da* odgovor, odnosno kada su oblici bili sukladni, ispitanici su bili za 36 ms brži kada je postojala i sukladnost broja nego kada nije bilo sukladnosti broja, $F(1,27) = 10.64$, $p = .006$. S druge strane, kada je trebalo dati *ne* odgovor, odnosno kada nije bilo sukladnosti oblika, nije bilo razlike između situacije kada je postojala sukladnost broja i kada nije bilo sukladnosti broja ($M_{da} - M_{ne} = 8$ ms), $F(1,27) = 1.10$, $p = .303$. Deskriptivni podaci za vrijeme reakcije za oba faktora prikazani su na slici 5.16.



Slika 5.16. Prosječno vrijeme reakcije (u sekundama) kada je postojala sukladnost pojma i oblika (lijevo) i kada nije (desno) te kada je postojala sukladnost broja i brojnosti (bijeli stupci) i kada nije (sivi stupci). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

Analiza točnosti. Na transformiranim vrijednostima provedena je dvosmjerna (2×2) ANOVA s ponavljanim mjerenjima na faktorima sukladnost broja (da ili ne) i sukladnost oblika (da ili ne). ANOVA je pokazala da postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,27) = 4.60$, $p = .041$, $\eta^2 = .15$, ali ne postoji glavni efekt sukladnosti broja, $F(1,27) = 2.31$, $p = .140$, $\eta^2 = .09$, a nema niti interakcije između sukladnosti oblika i sukladnosti broja, $F(1,27) = 2.25$, $p = .145$, $\eta^2 = .09$. Deskriptivni podaci za točnost za oba faktora prikazani su na slici 5.17.



Slika 5.17. Prosječna točnost odgovora (u postocima) kada je postojala sukladnost pojma i oblika (lijevo) i kada nije (desno) te kada je postojala sukladnost broja i brojnosti (bijeli stupci) i kada nije (sivi stupci). Linije oko aritmetičkih sredina predstavljaju 95% intervale pouzdanosti.

5.8.2. Analiza po riječima

Analiza vremena reakcije. ANOVA je pokazala da ne postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,60) = .04$, $p = .852$, $\eta^2 < .01$ niti glavni efekt sukladnosti broja, $F(1,60) = 3.55$, $p = .065$, $\eta^2 = .06$. Dvosmjerna interakcija između sukladnosti oblika i sukladnosti broja je statistički značajna, $F(1,60) = 11.86$, $p = .001$, $\eta^2 = .17$. Analiza jednostavnih efekata pokazala je da kada je trebalo dati odgovor *da*, odnosno kada su oblici bili sukladni, ispitanici su bili statistički značajno brži kada je postojala i sukladnost broja nego kada nije bilo sukladnosti broja, $F(1,60) = 12.44$, $p = .002$. S druge strane, kada je trebalo dati odgovor *ne*, odnosno kada nije bilo sukladnosti oblika, nije bilo razlike između situacije kada je postojala sukladnost broja i kada nije bilo sukladnosti broja, $F(1,60) = .99$, $p = .325$. Na taj način, u analizi po riječima, repliciran je glavni nalaz iz analize po ispitanicima da sukladnost broja interferira s izvođenjem zadatka utvrđivanja sukladnosti oblika, iako je sukladnost broja irelevantna za ovaj zadatak.

Analiza točnosti. ANOVA je pokazala da postoji statistički značajan glavni efekt sukladnosti oblika, $F(1,60) = 6.18$, $p = .016$, $\eta^2 = .09$, ali ne postoji glavni efekt sukladnosti broja, $F(1,60) = 1.79$, $p = .185$, $\eta^2 = .03$, niti interakcije između sukladnosti oblika i sukladnosti broja, $F(1,60) = 2.59$, $p = .113$, $\eta^2 = .04$.

6. DISKUSIJA

6.1. Eksperimenti 1 - 6

Prvih šest eksperimenata provedeno je s ciljem ispitivanja postoji li utemeljenje aritmetičkih operacija u kretanju duž zajedničke prostorne reprezentacije veličine koja obuhvaća i brojeve i svjetline. Prvi i drugi eksperiment ukazuju na postojanje trosmjerne interakcije između boje, aritmetičke operacije i vrste odgovora. Kada ispitanici daju pozitivan odgovor, brže reagiraju na zadatke zbrajanja kada su prezentirani u bijeloj nego u crnoj boji. S druge strane, ispitanici brže verificiraju zadatke oduzimanja kada su prezentirani u crnoj nego u bijeloj boji. Međutim, kada ispitanici daju negativan odgovor, dolazi do inverzije odnosno ispitanici brže reagiraju na zadatke zbrajanja kada su prezentirani u crnoj nego u bijeloj boji i brže reagiraju na zadatke oduzimanja kada su prezentirani u bijeloj nego u crnoj boji. Nadalje treći eksperiment je pokazao da se ovaj nalaz ne može svesti na reagiranje na znak za zbrajanje ili oduzimanje budući da nema interakcije između boje i pozitivnih i negativnih brojeva. Ovakav kompleksan rezultat može se analizirati s aspekta tri različita modela koji tumače interakciju između perceptivnih obilježja i pojmovnog znanja. To su:

1. Model trostrukog kodiranja prema kojem su simboli za brojeve utemeljeni u mentalnoj numeričkoj liniji (Dehaene i Cohen, 1995)

2. Teorija o korespondenciji polariteta između podražaja i odgovora koju su predložili Proctor i Cho (2006),

3. Pojmovno odnosno metaforičko preslikavanje između konkretne domene (boja) i apstraktne domene (aritmetika) kako to predlaže teorija o metaforičkom strukturiranju (Boroditsky, 2000; Lakoff i Núñez, 2000).

1. Prema modelu trostrukog koda, apstraktna simbolička reprezentacija brojeva u obliku znamenki ili riječi za brojeve povezana je s posebnim osjetom za brojeve odnosno sa sustavom za aproksimativnu reprezentaciju brojnosti. U ovom sustavu je smještena mentalna numerička linija koja reprezentira veličinu broja putem horizontalnog pravca na kojem su manje veličine smještene lijevo, a kako veličina brojeva raste tako se njihova reprezentacija sustavno pomiče u desno. Prema Dehaeneu (2011) osjet za brojeve doista funkcionira kao

zaseban osjetni sustav koji je evolucijski stariji od sustava za simboličke reprezentacije brojeva i kojeg dijelimo s drugim životinjskim vrstama. Model pretpostavlja dvosmjernu komunikaciju između simboličkih reprezentacija i osjeta za brojeve što znači da kada registriramo neku napisanu znamenku, ona će aktivirati vizualni sustav u kojem su pohranjeni vizualni kodovi za znamenke i koji će dalje aktivirati mentalnu numeričku liniju na mjestu koje odgovara značenju napisane znamenke. Drugim riječima, mentalna numerička linija aktivirat će se na mjestu koje predstavlja značenje te znamenke. Isto tako, registriranje napisane ili izgovorene riječi za broj aktivirat će sustav za verbalnu reprezentaciju koji će također aktivirati i osjet za brojeve koji će omogućiti razumijevanje značenja napisane ili izgovorene riječi. Dakle, može se reći da ovaj model pretpostavlja utemeljenje simbola za brojeve u mentalnoj numeričkoj liniji odnosno u percepciji brojnosti što je u skladu s postavkama teorije perceptivnih simboličkih sustava (Barsalou, 1999). Drugim riječima, mentalna numerička linija predstavlja osjetnu komponentu razumijevanja brojeva.

U okviru modela trostrukog koda, aritmetičke operacije zbrajanja i oduzimanja mogu se implementirati kao pomicanje duž numeričke linije, pri čemu zbrajanje predstavlja pomicanje udesno, a oduzimanje predstavlja pomicanje ulijevo na liniji. Kognitivna i neuroznanstvena istraživanja pokazuju da tijekom izvođenja aritmetičkih operacija dolazi do sustavnih kognitivnih pristranosti u procjeni veličine rezultata koja su sukladna pomacima na mentalnoj numeričkoj liniji. Na primjer, McCrink, Dehane i Dehaene-Lambertz (2007) su pokazali da kada ispitanici rješavaju zadatke ne-simboličke aritmetike odnosno pokušavaju odrediti približni rezultat zbrajanja ili oduzimanja skupova točkica dolazi do sustavnog precjenjivanja rezultata zbrajanja i podcjenjivanja rezultata oduzimanja. Drugim riječima, zbrajanje dovodi do pomicanja udesno koje se ne može odmah zaustaviti jer dolazi do kognitivne inercije i otklizavanja udesno na numeričkoj liniji. Isto tako, kod oduzimanja dolazi do pomicanja ulijevo koje kognitivnom inercijom otkliže prema manjim vrijednostima odnosno više ulijevo nego što treba. Ovaj efekt nazvan je operacijski moment po analogiji s perceptivnim momentom, a kasnije je repliciran i kod simboličke aritmetike što ukazuje na zajednički mehanizam nastanka ovog efekta (Knops, Viarouge i Dehaene, 2009). Tehnikom oslikavanja mozga pokazano je da se prilikom rješavanja aritmetičkih problema aktivira isti dio parijetalnog režnja koji je inače zadužen za programiranje pokreta oka. Zanimljivo je da je aktivacija tog centra prilikom zbrajanja slična aktivaciji koja se javlja prilikom pripreme pokreta oka udesno dok je aktivacija prilikom oduzimanja slična aktivaciji koja se javlja prilikom pripreme pokreta oka ulijevo. Ovaj nalaz ukazuje na zaključak da se prilikom izvođenja zbrajanja i oduzimanja, pažnja pomiče na mentalnoj numeričkoj liniji sukladno

pretpostavljenom smjeru kretanja za svaku operaciju (Knops, Thirion, Hubbard, Michel i Dehaene, 2009).

Kako bi se objasnila veza između aritmetike i svjetline, Dehaenenov model trostrukog koda potrebno je dopuniti s teorijom o direktnom preslikavanju između svjetlina i brojeva. Prema Walshu (2003), sve kvantitativne dimenzije preslikavaju se na zajedničku reprezentaciju veličina. Drugim riječima, mentalna numerička linija zapravo nije numerička linija nego linija veličina na koju se mogu preslikati brojevi, prostor, vrijeme, svjetline, visine zvuka itd. Kombinirajući pretpostavku da se tijekom izvođenja zbrajanja ili oduzimanja pažnja pomiče udesno ili ulijevo na numeričkoj liniji s pretpostavkom da numerička linija dijeli reprezentaciju veličine sa svjetlinama, dolazimo do objašnjenja da će se zbrajanje brže verificirati u bijeloj boji jer bijela boja aktivira desnu stranu numeričke linije na koju će doći rezultat zbrajanja što će dovesti do međusobnog pojačavanja aktivnosti desne strane numeričke linije pa time i do ubrzanja motornog odgovora. Međutim, kada je zbrajanje prezentirano u crnoj boji neće doći do takvog ubrzanja jer crna boja aktivira lijevu stranu, a rezultat zbrajanja desnu stranu numeričke linije pa neće biti posebne prednosti za desnu stranu linije odnosno neće biti ubrzanja u kodiranju i dozivu rezultata zbrajanja. S druge strane, oduzimanje će se brže verificirati u crnoj boji jer crna boja aktivira lijevu stranu numeričke linije odnosno područje gdje će doći rezultat oduzimanja. Drugim riječima, percipiranje boje u kojoj je prikazan problem dovest će do semantičke pripreme za doziv rezultata aritmetičke operacije i ubrzat će izvođenje one operacije čiji se rezultat nalazi u područje numeričke linije koja je prethodno već aktivirana percipiranom bojom. Naravno, ovo objašnjenje vrijedi samo uz dodatnu pretpostavku da je bijela boja povezana s desnom stranom numeričke linije odnosno s većim brojevima, a crna s lijevom stranom odnosno s manjim brojevima pri čemu su nijanse sive poredane između.

Direktnu potvrdu za ovu pretpostavku dobili su Cohen Kadosh i Henik (2008) koji su koristili zadatak numeričke kongruentnosti u kojem su ispitanici uspoređivali dva broja po veličini. Pri tome, brojevi su prikazivani u različitim nijansama sive. Rezultati su pokazali da ispitanici brže reagiraju na male brojeve kada su prikazani u crnoj boji, a na velike brojeve kada su prikazani u bijeloj boji, sukladno pretpostavci o zajedničkoj reprezentaciji veličina. Nedavno su Fumarola i sur. (2014) dobili sličnu povezanost između brojeva i svjetlina koristeći SNARC paradigmu. Međutim, u ranijem istraživanju pokazano je da je veza između boja i brojeva obrnuta, odnosno mali brojevi su povezani s bijelom bojom, a veliki brojevi s crnom (Cohen Kadosh i Henik, 2006). Ovaj rezultat u skladu je s rezultatima istraživanja sa sinestetičarima koji konzistentno male brojeve povezuju s bijelom, a velike brojeve s crnom

bojom (Cohen Kadosh, Henik i Walsh, 2007), kao i s razvojnom studijom koja je pokazala da mala djeca pokazuju preferenciju ka malim bijelim objektima i velikim crnim objektima (Smith i Sera, 1992). Gebuis i van der Smagt (2011) su zaključili da je veza između brojeva i svjetline vjerojatno indirektna odnosno posredovana kategorijalnim kodiranjem budući da nisu dobili vezu između veličine broja i svjetline kada se kontrolira veličina kontrasta neovisno o polaritetu svjetline. Nadalje, istraživanja oslikavanjem mozga također ne daju jasnu sliku o povezanosti brojeva i svjetlina. Naime, Cohen Kadosh i Henik (2006) su pokazali su da zadatak numeričke usporedbe i usporedbe nijansi svjetlina aktivira djelomično preklapajuće regije unutar parijetalnog režnja. Međutim, Pinel i sur. (2004) su dobili da postoji određeno preklapanje između reprezentacije brojeva i fizičkih veličina u parijetalnom režnju, ali da je reprezentacija svjetlina odvojena od njih.

Sljedeći problem s opisanim objašnjenjem dobivene interakcije je što pretpostavlja čvrstu, nepromjenjivu vezu između brojeva i svjetline što znači da bi se isti efekt trebao javiti bez obzira na vrstu odgovora. Drugim riječima, trebala bi se javiti samo dvosmjerna interakcija između boja i aritmetičke operacije, ali ne i trosmjerna interakcija koja uključuje i vrstu odgovora. Činjenica da je smjer efekta posredovan vrstom odgovora sugerira da dobiveni efekt nije posljedica interakcije tijekom osjetnog kodiranja svjetlina i brojeva nego nastaje na razini obrade informacija koja se aktivira kasnije nakon što je osjetna obrada gotova. Jedno moguće objašnjenje ove pojave jest da ispitanici kada se susretnu s netočnim zadatkom koriste strategiju u kojoj problem preformuliraju u suprotnu aritmetičku operaciju. Na primjer, kada pokušavaju odrediti da li je $7 + 9 = 18$ točno ili ne, moguće je problem transformirati u $18 - 9$ kako bi se potvrdilo da oduzimanje jednog operanda od rezultata ne daje drugi operand. Isto tako, kada se radi o oduzimanju moguće je transformirati problem $6 - 4 = 1$ u $1 + 4$ kako bi se potvrdilo da zbrajanje rezultata s drugim operandom ne daje prvi operand. Na taj način, moguće je objasniti obrnuti uzorak vremena reakcije za pozitivne i negativne odgovore jer se smjer kretanja duž numeričke linije okreće u suprotnom smjeru od uobičajenog za negativne odgovore. U prethodnim istraživanjima je pokazano da ispitanici doista koriste ovakvu strategiju posebno pri rješavanju zadataka oduzimanja i dijeljenja (Campbell, 2008; Campbell i Alberts, 2010). Nažalost, u istraživanjima provedenima u okviru ove doktorske disertacije nije se direktno pitao ispitanike koju su strategiju koristili nakon rješavanja pojedinog zadatka. Međutim, rezultati četvrtog i petog eksperimenta pokazuju da u situaciji kada ispitanici rješavaju samo zadatke zbrajanja ili samo zadatke oduzimanja unutar istog bloka pokušaja nema očekivane razlike u brzini verifikacije između prezentacije problema u bijeloj i crnoj boji. Nadalje, nema ni interakcije s vrstom odgovora. Ovakav nalaz

upućuje na zaključak da, bez obzira koju strategiju koriste ispitanici, aritmetičke operacije nisu utemeljene direktno u zajedničkoj prostornoj reprezentaciji brojeva i svjetlina jer bi veza između brojeva i svjetlina, ukoliko nastaje na razini senzornog kodiranja, trebala biti stabilna odnosno trebala bi se javljati bez obzira da li su zbrajanje i oduzimanje prezentirani zajedno unutar istog bloka ili u odvojenim blokovima te bi trebala biti ista i za pozitivne i negativne odgovore. Upravo činjenica da veza između aritmetike i svjetline ovisi o vrsti odgovora ukazuje na zaključak da je dobivena trosmjerna interakcija vjerojatno posljedica procesa koji se javljaju prilikom pripreme motornog odgovora odnosno usklađenosti između podražaja i odgovora koja je opisana u idućem poglavlju.

2. Proctor i Cho (2006) su predložili teoriju o korespondenciji polariteta kao generalnu teoriju koja objašnjava brzinu reagiranja u svim zadacima binarnoj izbora odnosno u zadacima u kojima se mora napraviti izbor između dvije alternative te kada podražajne dimenzije također imaju samo dvije vrijednosti. Važno je napomenuti da je veliki broj istraživanja s vremenom reakcije upravo ovakvog tipa. Osnovna ideja teorije je da ljudi prilikom rješavanja zadataka binarnog izbora kodiraju jednu podražajnu alternativu kao pozitivan pol, a drugu alternativu kao negativan pol. Isto tako, kodiraju se i mogući odgovori. Naime, u ovakvim zadacima odgovori su najčešće dani kao alternative DA/NE, ISTO/RAZLIČITO, TOČNO/NETOČNO, LIJEVO/DESNO. Jedna od alternativa odgovora postaje pozitivan pol, a druga negativan pol. Kada su polovi podražaja i odgovora isti, doći će do ubrzanja vremena reakcije u odnosu na situaciju kada polovi nisu isti. Drugim riječima, ubrzanje vremena reakcije u nekim situacijama ne mora biti posljedica preklapanja između senzornih reprezentacija, već može nastati zbog strukturalnog preklapanja između podražaja i odgovora. Kada postoji više podražajnih dimenzija izračunavaju se sume posebno za pozitivan i posebno za negativan polaritet, a nakon toga se uspoređuju sume za isti polaritet u različitim eksperimentalnim situacijama. Što je suma veća to znači i da će vrijeme reakcije biti brže jer postoji veća sukladnost polariteta. Proctor i Cho (2006) su pokazali da se analizom polariteta mogu objasniti mnogi rezultati u kognitivnoj psihologiji pa čak i SNARC efekt. Lakens (2011) je pokazao kako se mnoga istraživanja o metaforičkom preslikavanju značenja riječi na prostornu dimenziju gore-dolje mogu zapravo objasniti korespondencijom polariteta. Konkretnu potvrdu za pretpostavku da bi SNARC efekt mogao biti posljedica kategorijalnog kodiranja prostornog odnosa lijevo-desno i uspostavljanja korespondencije polariteta između kategorijalnih kodova i odgovora dobili su Santens i Gevers (2008) i Gevers i sur. (2010).

Kada primijenimo teoriju korespondencije polariteta na prikazane rezultate, možemo pretpostaviti da se u prvom i drugom eksperimentu zbrajanje kodira kao pozitivan pol varijable aritmetička operacija, a oduzimanje kao negativan pol. Isto tako, bijelo se može kodirati kao pozitivan pol, a crno kao negativan pol budući da bijelo u odnosu na sivu pozadinu predstavlja povećanje svjetline, a crno predstavlja smanjenje svjetline. Nadalje, kada promatramo polaritete odgovora ispitanika, odgovor *da* se kodira kao pozitivan pol, a odgovor *ne* kao negativan pol. Kada usporedimo polaritete podražaja i odgovora dolazimo do sljedećih predikcija o brzini reagiranja. Kada je točan odgovor *da*, ispitanici bi trebali brže verificirati zbrajanje u bijeloj boji nego u crnoj jer u prvom slučaju imamo tri plusa, a u drugom slučaju samo dva plusa, što znači da će zbrajanje u bijeloj boji ubrzati reagiranje zbog usklađenosti polariteta. Ova predikcija u skladu je s dobivenim rezultatima. S druge strane, oduzimanje bi se također trebalo brže verificirati u bijeloj boji jer u toj situaciji postoje dva plusa dok u situaciji oduzimanja u crnoj boji imamo samo jedan plus što implicira sporiju reakciju. Međutim, dobiveni rezultati pokazuju upravo obrnuto, oduzimanje se brže verificiralo kada je bilo prezentirano u crnoj nego u bijeloj boji. Kada je točan odgovor *ne*, ispitanici bi trebali biti brži kada je zbrajanje u crnoj boji (dva minusa) nego bijeloj (jedan minus), što je i dobiveno. Međutim, kod oduzimanja, teorija predviđa brže reagiranje na prezentaciju u crnoj boji (tri minusa), u odnosu na prezentaciju u bijeloj boji što nije dobiveno. Iz navedene analize proizlazi da teorija korespondencije polariteta ne može na zadovoljavajući način objasniti dobivene razlike u vremenu reakcije jer objašnjava rezultate samo za zbrajanje, ali ne i za oduzimanje. Kako bi bilo jasnije opisano slaganje polariteta i predikcije o brzini reagiranja, u Tablici 6.1. prikazane su sve podražajne situacije i pripadajući im polariteti. Polariteti se zasebno zbrajaju i što je suma veća za određeni odgovor to bi trebalo dovesti do bržeg reagiranja odnosno do kraćeg vremena reakcije.

Tablica 6.1. Polariteti svih dimenzija uključenih u prvom i drugom eksperimentu

Operacija	+ Zbr	+ Zbr	- Oduz	- Oduz	+ Zbr	+ Zbr	- Oduz	- Oduz
Boja	+ B	- C	+ B	- C	+ B	- C	+ B	- C
Odgovor	+ Da	+ Da	+ Da	+ Da	- Ne	- Ne	- Ne	- Ne
Suma +	3	2	2	1	2	1	1	0
Suma -	0	1	1	2	1	2	2	3

Tumač. Zbr – zbrajanje, Oduz – oduzimanje, B – bijelo, C – crno.

3. Na kraju, potrebno je razmotriti i treću mogućnost da je otkrivena interakcija posljedica veze koja nastaje na nivou obrade informacija koja se odvija nakon senzornog kodiranja, odnosno procesa na mentalnoj numeričkoj liniji, ali prije pripremanja motornog odgovora. Drugim riječima, moguće je da se veza između boja i aritmetičkih operacija uspostavlja na razini pojmovne odnosno kategorijalne obrade. Prema teoriji o pojmovnim metaforama koju su predložili Lakoff i Johnson (1980, 1999) razumijevanje apstraktnih pojmova odvija se putem preslikavanja svojstava apstraktne domene na obilježja neke konkretne (perceptivne ili motorne) iskustvene domene. Ovu ideju dalje je razvila Boroditsky (2000) koja je pokazala kako se vrijeme može metaforički strukturirati putem preslikavanja na konkretnu domenu prostora. Nadalje, Lakoff i Núñez (2000) su pokazali kako se ista analiza može primijeniti i na razumijevanje matematičkih pojmova. Iako Lakoff i Núñez (2000) nisu direktno proučavali ovu mogućnost, iz njihove teorije moguće je derivirati pretpostavku da ispitanici automatski kreiraju analogiju između aritmetičkih operacija i svjetlina na način da detektiraju strukturnu vezu između zbrajanja kao procesa koji dovodi do povećanja veličine i bijele boje koja predstavlja povećanje svjetline kada se promatra s obzirom na sivu pozadinu. Na isti način, oduzimanje kao proces koji dovodi do smanjenja veličine metaforički može biti povezan s crnom bojom koja predstavlja smanjenje svjetline u odnosu na sivu pozadinu. Dakle, i zbrajanje i bijela boja dijele zajedničko svojstvo da označavaju porast u veličini, kao što i oduzimanje i crna boja dijele svojstvo da označavaju pad veličine.

Iako ova hipoteza objašnjava zašto bi postojala veza između aritmetičkih operacija i svjetline i ona ima problem objasniti trosmjernu interakciju odnosno ne daje odgovor na pitanje zašto postoji obrnuti uzorak rezultata kod pozitivnih i negativnih odgovora. Moguće objašnjenje leži u povezivanju metaforičkog strukturiranja s teorijom o korespondenciji polariteta. Naime, ako se doista uspostavi analogija između operacije i svjetline tada su podražajni parovi zbrajanje-bijelo i oduzimanje-crno sukladni metaforičkom preslikavanju pa bi oboje trebali biti označeni istim pozitivnim polaritetom. S druge strane, podražajni parovi, zbrajanje-crno i oduzimanje-bijelo nisu sukladni uspostavljenom metaforičkom preslikavanju te bi trebali biti označeni negativnim polaritetom. Kada se ovi kombinirani podražajni polariteti povežu s polaritetom odgovora, dolazimo do situacije u kojoj će pozitivan odgovor biti brži za podražajne parove zbrajanje-bijelo i oduzimanje-crno nego za parove zbrajanje-crno i oduzimanje-bijelo. S druge strane, za negativan odgovor, očekuje se upravo suprotno jer su parovi zbrajanje-crno i oduzimanje-bijelo označeni negativnim polaritetom kao što je i sam negativni odgovor pa će doći do brže reakcije nego na parove označene pozitivnim polaritetom tj. na parove zbrajanje-bijelo i oduzimanje-crno. Upravo ovakav uzorak

aritmetičkih sredina je i dobiven u prvom i drugom eksperimentu. Ključno za ovu interpretaciju je da podražajne dimenzije (aritmetička operacija i svjetlina) stupaju u interakciju prije nego započne proces usklađivanja polariteta s motornom reakcijom. Dakle, pretpostavlja se dinamičko formiranje kombiniranih kodova koji reprezentiraju aspekte tekuće podražajne situacije. Za razliku od toga, teorija o korespondenciji polariteta pretpostavlja da podražajne dimenzije zasebno formiraju polaritete i neovisno jedna o drugoj stupaju u interakciju s polaritetom odgovora. Kao što je opisano u prethodnom poglavlju, iz takve interpretacije proizlaze predviđanja o brzini reagiranja koja ne odgovaraju dobivenim podacima. S druge strane, predviđanja o vremenu reakcije koja proizlaze iz hipoteze o metaforičkom strukturiranju prikazana su u Tablici 6.2. Iz tablice vidimo da pojmovni parovi zbrajanje-bijelo i oduzimanje-crno dovode do bržeg vremena reakcije u odnosu na parove zbrajanje-crno i oduzimanje-bijelo kada je traženi odgovor *da*. S druge strane, pojmovni parovi zbrajanje-crno i oduzimanje-bijelo dovode do bržeg vremena reakcije u odnosu na parove zbrajanje-bijelo i oduzimanje-crno kada je traženi odgovor *ne* što je u skladu s dobivenim podacima.

Tablica 6.2. Polariteti pojmovnih parova i odgovora prema hipotezi o metaforičkom strukturiranju

Pojmovni parovi	+ (ZB)	- (ZC)	- (OB)	+ (OC)	+ (ZB)	- (ZC)	- (OB)	+ (OC)
Odgovor	+ Da	+ Da	+ Da	+ Da	- Ne	- Ne	- Ne	- Ne
Suma +	2	1	1	2	1	0	0	1
Suma -	0	1	1	0	1	2	2	1

Tumač. ZB – zbrajanje i bijelo, ZC – zbrajanje i crno, OB – oduzimanje i bijelo, OC – oduzimanje i crno.

Nadalje, predloženo objašnjenje u skladu je i s nalazom iz četvrtog i petog eksperimenta u kojima je dobiveno da kada ispitanici rješavaju samo zadatke zbrajanja ili samo zadatke oduzimanja ne dolazi do očekivanog utjecaja boje na brzinu zbrajanja ili oduzimanja, barem kada je u pitanju odgovor *da* (kod odgovora *ne*, javlja se efekt boje koji se može objasniti korespondencijom polariteta).

Naime, u tim situacijama ne može se formirati metaforičko preslikavanje jer nedostaje jedan član binarne dimenzije odnosno ispitanici neće detektirati strukturalnu vezu između aritmetike i akromatskih boja. Drugim riječima, metaforičko preslikavanje je dinamičan, fleksibilan proces koji ovisi o trenutno aktiviranim reprezentacijama odnosno o kontekstu u kojem se odvija pojmovna obrada, a ne statičan proces koji se uvijek oslanja na iste fiksne veze među domenama. Ovakva interpretacija u skladu je s prethodnim istraživanjima koja ukazuju na fleksibilnost pojmovnog znanja. Na primjer, kada se ispitanike pita koja je tipična boja lubenice, najčešći odgovor je zelena boja. Međutim, ako se najprije traži od njih da zamisle prepolovljene lubenice i zatim ih se pita za tipičnu boju, najčešći odgovor je da su lubenice crvene boje (Barsalou, 1982).

6.2. Eksperimenti 7 i 8

Za razliku od prvih šest eksperimenata u kojima je pokazano da iako postoji interakcija između aritmetičkih operacija i svjetlina ne možemo tvrditi da su aritmetičke operacije utemeljene u pomacima pažnje na mentalnoj numeričkoj liniji, u sedmom i osmom eksperimentu pokušalo se provjeriti postoji li utemeljenje brojeva u sustavu za subitizaciju odnosno u sustavu zaduženom za brzo prebrojavanje malih veličina (Trick i Pylyshyn, 1994). U tu svrhu dizajnirana je nova varijanta numeričkog Stroopovog efekta koja rješava važne prigovore prijašnjim istraživanjima (Pansky i Algom, 1999; 2002).

I u sedmom i u osmom eksperimentu dobivena je dvosmjerna interakcija između sukladnosti oblika i sukladnosti broja. Ovaj rezultat se može analizirati s aspekta tri modela. Kao i kod prvih šest eksperimenata, jedna mogućnost je da dobivena interakcija nastaje kao posljedica korespondencije polariteta između podražaja i odgovora (Proctor i Cho, 2006). Prema ovom objašnjenju, ispitanici će biti brži u onim situacijama kada se poklapaju polariteti podražaja i odgovora. S obzirom da ispitanici moraju odgovoriti s *da* ili *ne*, možemo pretpostaviti da odgovor *da* postaje označen kao pozitivan pol, dok odgovor *ne* postaje označen kao negativan pol. Na isti način, iako je to nebitno za samo rješavanje zadatka, podražajna situacija u kojoj postoji podudarnost između prezentirane riječi za broj i brojnosti objekata na slici može postati označena kao pozitivan pol, dok situacija u kojoj nema podudarnosti između simbola za broj i brojnosti objekata može biti označena kao negativan pol. Iz toga proizlazi da će ispitanici biti brži s davanjem odgovora *da* kada istovremeno postoji preklapanje između broja i veličine, što je doista i dobiveno u oba eksperimenta. Međutim, problem za ovo objašnjenje nastaje kada razmotrimo što se događa s odgovorom

ne. U ovom slučaju teorija korespondencije polariteta predviđa da će ispitanici biti brži s davanjem odgovora *ne* kada istovremeno ne postoji preklapanje između broja i veličine jer dijele isti polaritet, što nije dobiveno jer je post-hoc analiza pokazala da nema razlike između sukladnosti i nesukladnosti na dimenziji broj-veličina kada je točan odgovor *ne*.

Drugo moguće objašnjenje dobivene interakcije odnosi se na pojavu pripreme ponavljanjem (*repetition priming*) unutar istog sustava za simboličku reprezentaciju brojeva. U prethodnim istraživanjima dobiveno je da kada se isti podražaj prezentira dvaput unutar kratkog vremenskog intervala, dolazi do bržeg i točnijeg odgovora nakon druge prezentacije (Logan, 1990; Roediger i McDermott, 1993). Ovaj efekt može se objasniti činjenicom da neuralna aktivacija reprezentacije danog podražaja nije potpuno nestala nakon prve prezentacije nego još uvijek postoje tragovi stimulacije koji postupno blijede zbog čega ponovna prezentacija podražaja dovodi do brže reaktivacije iste neuronske reprezentacije koja dalje dovodi do bržeg odgovora (Grill-Spector, Henson i Martin, 2006; James i Gauthier, 2006). Ovo objašnjenje može se prilagoditi sedmom i osmom eksperimentu na način da pretpostavimo postojanje jednosmjerne veze od sustava za subitizaciju prema verbalnom sustavu. Dakle, kada sustav za subitizaciju detektira određeni broj objekata u vidnom polju, on će proslijediti aktivaciju u verbalni sustav i to točno onoj reprezentaciji riječi koja odgovara veličini skupa objekata. S druge strane, kada pročitamo ili čujemo riječ za broj, verbalni sustav ne prosljeđuje aktivaciju prema sustavu za subitizaciju. Drugim riječima, sva relevantna obrada informacija odvija se unutar sustava za simboličku reprezentaciju (riječi i znamenke) i nema potrebe za utemeljenjem u osjetnom sustavu, što znači da ovo objašnjenje možemo klasificirati kao amodalno.

Na kraju, treba razmotriti i mogućnost dvosmjerne komunikacije između verbalnog sustava i sustava za subitizaciju koja može pružiti osnovu za utemeljenje barem za reprezentaciju značenja malih brojeva. Kako bi se lakše dobila precizna predviđanja o vremenu reakcije koja proizlaze iz dvosmjerne komunikacije između dva različita modula potrebno je osloniti se na neuroračunalni model kao što je teorija adaptivne rezonance koji daje detaljna objašnjenja kako informacije iz jednog modula utječu na drugi. Stoga je u idućem poglavlju opisana teorija adaptivne rezonance. Zatim je objašnjeno kako bi ona mogla simulirati neke od nalaza o utemeljenoj spoznaji. Na kraju je dano i okvirno objašnjenje rezultata sedmog i osmog eksperimenta koje proizlazi iz mehanizama koje predlaže ova teorija.

6.3. Neurodinamički model utemeljenja simbola

Adekvatan teorijski okvir za razumijevanje utemeljenja simbola predstavlja teorija adaptivne rezonance (Carpenter i Grossberg, 2003, Grossberg, 2012). Ovaj model učenja kategorija razvijen je s ciljem rješavanja jednog od temeljnih problema s kojim se suočavaju svi neuronski modeli sa sposobnošću učenja, a to je katastrofalno zaboravljanje odnosno retroaktivna interferencija. Problem možemo ilustrirati pomoću primjera. Ako određenu neuronsku mrežu (npr. višeslojni perceptron) izložimo nekom skupu podražaja, ona će nakon većeg broja pokušaja uspjeti razlikovati podražaje s obzirom na sličnosti i razlike među njima. Drugim riječima, neuronska mreža će putem algoritma za učenje uspjeti izgraditi internalni model okoline u kojoj se nalazi i uspješno kategorizirati (razlikovati) podražaje s obzirom na njihova obilježja. Međutim, ako istu mrežu izložimo novom skupu podražaja koji do sada nisu bili prezentirani, mreža će početi graditi novi internalni model kako bi uspješno kategorizirala nove podražaje, ali će pri tome obrisati stare kodove odnosno izgubit će sposobnost kategoriziranja starih podražaja koje je prethodno naučila. Upravo nestabilnost učenja, odnosno gubitak naučenih informacija, inspirirala je Grossberga i njegove suradnike na formuliranje i rješavanje temeljne dileme s kojim se suočava svaki neuronski sustav sa sposobnošću učenja, a to je dilema između stabilnosti i plastičnosti. Dilema se sastoji u tome kako napraviti kompromis između stabilnosti tj. očuvanja prethodno naučenih kodova i plastičnosti tj. spremnosti da se uče novi kodovi, a da se istovremeno ne izbrišu oni već naučeni. Grossberg smatra da se ovaj problem može riješiti ako neuronski sustav uspijeva razlikovati poznate uzorke tj. one uzorke koje je već upamtio i nepoznate uzorke, tj. one uzorke kojima još nije bio izložen. Da bi to bilo moguće neuronski sustav za učenje i prepoznavanje kategorija mora podijeliti resurse za obradu informacija na dva dijela. Drugim riječima, neuronski model mora imati dva odvojena podsustava: podsustav pažnje i podsustav orijentacije (Carpenter i Grossberg, 2003; Grossberg, 2012).

Podsustav pažnje obrađuje poznate uzorke. On se sastoji od dva sloja neurona koji su međusobno potpuno recipročno povezani. Prvi sloj (F1) registrira uzorak koji dolazi iz osjetnih organa ili neke druge neuronske mreže. Neuroni iz F1 sloja šalju signale u F2 sloj koji registrira skalarni produkt signala iz F1 sloja i sinaptičkih efikasnosti. U F2 sloju postoje snažne inhibitorne veze među neuronima tako da nakon određenog vremena samo jedan neuron u F2 sloju ostaje aktivan, koji predstavlja kategoriju za dani uzorak. Zatim, F2 neuron šalje signale natrag u sloj F1 putem povratnih veza, čija se efikasnost također može mijenjati. Sada F1 sloj može izračunati koliko se uzorak koji je stigao izvana preklapa sa uzorkom kojeg

je učitao F2 neuron. Ako je preklapanje veliko, mreža je prepoznala uzorak, tj. uzorak je već prije bio naučen, tako da nije potrebno mijenjati sinaptičke efikasnosti. Pri tome, neuroni iz oba sloja, budući da su povezani ekscitatornim vezama, međusobno pojačavaju svoju aktivnost i mreža ulazi u stanje rezonance.

Međutim, ako je preklapanje malo, mreža se nalazi pred novim uzorkom. Sada se aktivira sustav za orijentaciju. On resetira aktivne F2 neurone odnosno onemogućuje njihovo ponovno aktiviranje nakon resetiranja. Budući da je F2 sloj potpuno neaktivan nakon resetiranja, F1 sloj ponovo šalje signale prema F2 sloju, te se izračunava skalarni produkt. Putem lateralne inhibicije traži se onaj neuron koji ima najveću aktivnost. To ne može biti isti neuron koji je prethodno resetiran jer ga sustav za orijentaciju inhibira i onemogućuje mu ponovnu aktivaciju. Novi F2 neuron šalje signale u F1 sloj i cijeli postupak se ponavlja. Na taj način mreža može pretražiti sve svoje kodove kako bi pronašla onaj uzorak koji se najviše preklapa sa uzorkom registriranim u F1 sloju. Ako niti jedan F2 neuron ne udovoljava kriteriju, izabire se novi F2 neuron koji još nema promijenjene sinaptičke efikasnosti te se one mijenjaju u skladu sa uzorkom u F1 sloju. Pri tome se mijenjaju efikasnosti i na F1 i na F2 sloju. Prilikom mijenjanja sinaptičkih efikasnosti, F1 i F2 neuroni postaju bolje povezani te dolazi do međusobnog pojačavanja aktivnosti, tj. rezonance, a budući da je rezonanca posljedica adaptivnih promjena na sinapsama ova je neuralna arhitektura dobila ime teorija adaptivne rezonance (Carpenter i Grossberg, 2003; Grossberg, 2012).

Kriterij koji određuje koliko se registrirani uzorak u F1 sloju mora poklapati sa očitanim uzorkom iz F2 sloja određuje budnost mreže. To je parametar vezan uz podsustav za orijentaciju, a može imati vrijednosti između 0 i 1. Ako je budnost mreže mala, rijetko će dolaziti do aktiviranja podsustava za orijentaciju, te će mreža moći kodirati samo one uzorke među kojima postoji velika razlika, dok će slične uzorke tretirati kao primjere iste generalne kategorije. S druge strane ako je budnost visoka, mreža će postati osjetljiva na male razlike u uzorcima. Podsustav za orijentaciju može primiti povratnu informaciju iz okoline o tome kolika je uspješnost kategoriziranja te na taj način mijenjati razinu budnosti. Na primjer, ako je početna budnost mala, te zbog toga mreža napravi grešku u kategorizaciji, povratna informacija iz okoline može povećati budnost kako bi kategorije postale preciznije (Carpenter i Grossberg, 2003). U ovom modelu nije potreban učitelj ili nadglednik koji određuje točno rješenje kao što je to slučaj s drugim neuronskim modelima kategorijalnog učenja. Nasuprot tome, neuronska mreža sama rješava kategorizacijski problem bez vanjske pomoći putem procesa samo-organizacije. To je proces kojim sustav sam reorganizira svoje kodove za

prepoznavanje, odnosno promjene na sinapsama spontano nastaju kao posljedica interakcije sa okolinom. Takva vrsta učenja naziva se učenje bez nadgledanja (*unsupervised learning*).

Teorija adaptivne rezonance primijenjena je u analizi i objašnjenju velikog broja ponašajnih i neuroznanstvenih rezultata o učenju i pamćenju (Grossberg, 1980). Na primjer, Banquet i Grossberg (1987) su pokazali da globalni inhibicijski signal kojeg odašilje podsustav orijentacije kako bi resetirao cijelu mrežu ima obilježja P300 vala u elektrofiziološkim mjerenjima koji se aktivira u zadacima detekcije novosti odnosno u situaciji kada dolazi do konflikta između prethodno prikazanih podražaja i novog podražaja. Carpenter i Grossberg (1993) su pokazali da oštećenje ili disfunkcija podsustava orijentacije dovodi do simptoma sličnih anterogradnoj amneziji jer podsustav orijentacije ne može usmjeriti pažnju na nove podražaje te stoga mreža ne može naučiti ništa novo dok su stari kodovi ostali sačuvani. Nasuprot tome, hipersenzibilan podsustav orijentacije dovodi do simptoma sličnih autizmu jer se sustav orijentacije pretjerano aktivira te dovodi do hiperspecifičnog učenja kategorija što za posljedicu ima potrebu za stabilnom okolinom koja se ne mijenja često (Grossberg i Seidman, 2006). Nadalje, rezonanca između slojeva F1 i F2 tijekom perceptivnog grupiranja može se povezati sa obilježjima svjesnog iskustva prepoznavanja (Grossberg, 1999; 2007).

Stoga se može opravdano postaviti pitanje mogu li se opisani mehanizmi teorije adaptivne rezonance generalizirati i na objašnjenje fenomena utjelovljenja. Domijan i Šetić (2009; 2016) su pokazali kako se različiti rezultati istraživanja o utemeljenju pojmovnog znanja u percepciji mogu simulirati koristeći mehanizme koje predlaže teorija adaptivne rezonance. Prije svega, sloj F1 može se promatrati kao perceptivna reprezentacija odnosno kao neuronska registracija perceptivnih obilježja prisutnih u danom podražaju. S druge strane, sloj F2 može se promatrati kao pojmovno znanje zato jer sadrži reprezentaciju apstraktnih grupiranja perceptivnih obilježja. Drugim riječima, sloj F2 sadrži znanje o obilježjima kategorije odnosno pojma. S obzirom na to da su sloj F1 i F2 povezani obostranim vezama, kako je to objašnjeno u prethodnim odlomcima, njihovo zajedničko aktiviranje dovest će do ubrzanja ili usporenja donošenja odluke u zadacima izbornog vremena reakcije ovisno o usklađenosti kodova u F1 i F2. Konkretnije, Domijan i Šetić (2009) pokušali su objasniti (simulirati) rezultate istraživanja Zwaan i sur. (2004) o interakciji između percepcije pokreta i razumijevanja rečenica koje opisuju kretanje. U istraživanju, ispitanici su slušali rečenice, a nakon toga je uslijedila prezentacija objekta kojim je induciran određeni smjer pokreta. Rečenica koja je prethodila prezentaciji objekta mogla je govoriti o smjeru kretanja koji je konzistentan sa smjerom kretanja objekta ili koji je suprotan od smjera kretanja objekta.

Rezultati su pokazali da je vrijeme potrebno da se riješi perceptivni zadatak kraće kada rečenica govori o istom smjeru kretanja koji je prikazan nego u situaciji kada rečenica govori o suprotnom smjeru kretanja od onog prikazanog.

Objašnjenje ovog efekta leži u povratnim vezama od sloja F2 prema sloju F1. Kada se u F2 sloju aktivira neuron koji reprezentira kretanje prema gore tada će povratne veze od sloja F2 prema F1 pripremiti aktivaciju neurona u sloju F1 koji reprezentira percepciju kretanja prema gore. Aktivacija sloja F2 prije sloja F1 javlja se zato jer ispitanici slušaju ili čitaju rečenice koje opisuju kretanje objekata pa time aktiviraju kategorijalne kodove koji odgovaraju registriranim riječima. Pri tome, treba napomenuti da se ovdje nije radilo o cjelovitoj simulaciji razumijevanja rečenica koja bi zahtijevala mnogo složeniju neuronsku mrežu, već samo simulaciji aspekata leksičke semantike odnosno doziva značenja riječi iz dugoročnog pamćenja. Ako nakon aktivacije sloja F2 uslijedi aktivacija neurona u sloju F1 koji odgovara kategoriji doći će do bržeg formiranja rezonance između slojeva F1 i F2 zbog čega će se brže odgovoriti na postavljeni zadatak. Dakle, doći će do poklapanja aktivnosti u sloju F1 i F2 čime je spriječeno aktiviranje sustava za orijentaciju, odnosno neće doći do reseta mreže. S druge strane, ako nakon aktivacije sloja F2 uslijedi aktivacija neurona u sloju F1 koji ne odgovara prethodno aktiviranoj kategoriji doći će do aktiviranja sustava za orijentaciju zbog toga što se cijela mreža mora vratiti u početno stanje kako bi mogla primiti novi podražaj. Zbog pojave reseta, doći će do usporavanja u procesu formiranja rezonance između slojeva F1 i F2, a kao posljedica toga usporit će se odgovaranje na postavljeni zadatak. Drugim riječima, razlika u vremenu reakcije između situacije u kojoj se percepcija i prethodno aktivirana kategorija slažu i situacije u kojoj se percepcija i kategorija ne slažu nastaje kao posljedica činjenice da u prvom slučaju ne dolazi do reseta mreže, a u drugom slučaju dolazi do reseta koji usporava dinamiku mreže.

Isto objašnjenje dano u gornjem odlomku može se primijeniti i na rezultate dobivene u eksperimentu 7 i 8. Naime, možemo pretpostaviti da F2 sloj posjeduje reprezentaciju brojeva, a da je ta reprezentacija povezana s perceptivnom reprezentacijom F1 koja kodira broj objekata u vidnom polju. Ovakva reprezentacija brojnosti može nastati kodiranjem objekata u vidnom radnom pamćenju, pri čemu svaki objekt dobiva jedinstveni kod odnosno različitu razinu neuronske aktivacije kako bi se mogao razlikovati od drugih objekata (Domijan, 2011). Na taj način, neuronska aktivacija u mreži za vidno radno pamćenje postaje pokazivač na objekte kako to predlažu Trick i Pylyshyn (1994). Na osnovu opisanog koda iz F1, sloj F2 može razlikovati situacije, odnosno može naučiti razlikovati situacije kada je prezentiran jedan, dva, tri ili četiri objekta. Reprezentacija pet ili više objekata nije moguća jer prelazi

kapacitet vidnog radnog pamćenja (Luck i Vogel, 1997). Najvažnija spoznaja koja proizlazi iz ovih simulacija i razmatranja je da utemeljenje nije slučajno, usputni rezultat interakcija u mozgu kako to predlaže hipoteza o sekundarnom utjelovljenju (Mahon i Caramazza, 2008), već nastaje zbog istih mehanizama koji osiguravaju stabilnost kategorijalnog učenja. Drugim riječima, teorija adaptivne rezonance daje mehanicističko objašnjenje zašto utjelovljenje uopće postoji (Domijan i Šetić, 2016).

7. ZAKLJUČAK

Na osnovu dobivenih rezultata možemo zaključiti sljedeće:

1. Postoji interakcija između brzine rješavanja aritmetičkih operacija i boje u kojoj su aritmetički problemi prikazani, ali ona je kompleksnija nego što se očekivalo. Naime, utvrđeno je postojanje trosmjerne interakcije između boje, aritmetičke operacije i odgovora ispitanika. Ovaj nalaz javlja se i u situaciji kada su aritmetički problemi prikazani kao riječi.
2. Ne postoji razlika u brzini obrade pozitivnih i negativnih brojeva kada su prezentirani u bijeloj i crnoj boji. Drugim riječima, interakcija između boje i operacije opisana u prethodnoj točki ne može se svesti na različito reagiranje na znakove plus i minus i njihovu moguću vezu s mentalnom numeričkom linijom.
3. Očekivani utjecaj boje na brzinu rješavanja aritmetičkih operacija ne javlja se u situaciji kada ispitanici rješavaju samo zadatke zbrajanja ili samo zadatke oduzimanja unutar istog bloka pokušaja. Preciznije, boja nema utjecaja na brzinu rješavanja zadataka kada je točan odgovor *da*. Kada je točan odgovor *ne*, ispitanici brže rješavaju zadatke u crnoj boji, što se može objasniti kao posljedica korespondencije polariteta. Iz toga proizlazi da je interakcija između aritmetičkih operacija i boje opisana pod točkom 1. vjerojatnije posljedica kategorijalnog kodiranja, odnosno registriranja kategorijalnih suprotnosti bijelo-crno i zbrajanje-oduzimanje, a ne preslikavanja na zajedničku reprezentaciju veličina.
4. Ne postoji interakcija između brzine rješavanja aritmetičkih operacija množenja i dijeljenja i boje kojom su aritmetički problemi prikazani.
5. Postoji interferencija u brzini rješavanja zadatka usporedbe riječi i slike kada riječ za broj ne odgovara broju objekata prikazanih na slici. Ovaj se efekt javlja iako su i riječ za broj i brojnost objekata irelevantni za zadatak.
6. Interferencija opisana u prethodnoj točki javlja se i u situaciji kada se prezentiraju cijele rečenice koje još više odvlače pažnju od numeričke dimenzije.

S obzirom na temeljno pitanje utemeljenja numeričkih pojmova u percepciji možemo zaključiti kako nema argumenata da se brojevi preslikavaju na zajedničku reprezentaciju veličine, već se dobiveni efekti mogu objasniti metaforičkim preslikavanjem između kategorijalnih suprotnosti (bijelo-crno i zbrajanje-oduzimanje). S druge strane, rezultati 7. i 8. eksperimenta odnosno pojava interferencije kada se ne podudaraju broj i brojnost u zadatku usporedbe riječi (ili rečenica) i slike daje snažniju potvrdu da je značenje malih brojeva utemeljeno u sustavu za subitizaciju. Opći zaključak koji proizlazi iz ovog istraživanja je da značenje numeričkih pojmova može biti utemeljeno u sustavu za subitizaciju, ali i ne i u zajedničkom sustavu za reprezentaciju veličina odnosno u mentalnoj numeričkoj liniji, što djelomično ide u prilog teoriji perceptivnih simboličkih sustava.

8. LITERATURA

- Agrillo, C., Piffer, L., Bisazza, A. i Butterworth, B. (2012). Evidence for two numerical systems that are similar in humans and guppies. *PLoS ONE*, 7(2): e31923.
- Anderson, J. R. (1990). *The adaptive character of thought*. Mahwah, NJ: Erlbaum.
- Andrews, M., Vigliocco, G., Vinson, D. P. (2009). Integrating experiential and distributional data to learn semantic representations. *Psychological Review*, 116, 463-498.
- Ansari, D., Lyons, I. M., van Eimeren, L. i Xu, F. (2007). Linking visual attention and number processing in the brain: The role of the temporo-parietal junction in small and large symbolic and nonsymbolic number comparison. *Journal of Cognitive Neuroscience*, 19, 1845-1853.
- Ashcraft, M. H. i Battaglia, J. (1978). Cognitive arithmetic: Evidence for retrieval and decision processes in mental addition. *Journal of Experimental Psychology: Human Learning and Memory*, 4, 527-538.
- Banquet, J. P. i Grossberg, S. (1987). Probing cognitive processes through the structure of event-related potentials during learning: An experimental and theoretical analysis. *Applied Optics*, 26, 4931-4946.
- Barth, H., La Mont, K., Lipton, J.S. i Spelke, E.S. (2005). Abstract number and arithmetic in preschool children. *Proceedings of the National Academy of Sciences of the United States of America*, 102, 14116-14121.
- Barsalou, L. W. (1982). Context-independent and context-dependent information in concepts. *Memory & Cognition*, 10, 82-93.
- Barsalou, L. W. (1999). Perceptual symbol systems. *Behavioral and Brain Sciences*, 22, 577–660.
- Barsalou, L. W. (2003). Situated simulation in the human conceptual system. *Language and Cognitive Processes*, 18, 513-562.
- Barsalou, L. W. (2008). Grounded cognition. *Annual Review of Psychology*, 59, 617-645.
- Barsalou, L. W. (2010). Grounded cognition: Past, present, and future. *Topics in Cognitive Science*, 2, 716-724.
- Barsalou, L. W., Niedenthal, P. M., Barbey, A. K. i Ruppert, J. A. (2003). Social embodiment. U B.H. Ross, *The psychology of learning and motivation*, vol. 43 (str. 43-92). New York: Academic Press.

- Barsalou, L. W., Simmons, W.K., Barbey, A.K. i Wilson, C.D. (2003). Grounding conceptual knowledge in modality-specific systems. *Trends in Cognitive Sciences*, 7, 84-91.
- Barsalou, L. W. i Wiemer-Hastings, K. (2005). Situating abstract concepts. U D. Pecher i R. Zwaan (Ur.), *Grounding cognition: The role of perception and action in memory, language, and thought* (str. 129-163). New York: Cambridge University Press.
- Berent, I., Pinker S., Tzelgov J., Bibi U. i Goldfarb L. (2005). Computation of semantic number from morphological information. *Journal of Memory and Language*, 53, 342-358.
- Binder, J. R., Desai, R. H., Graves, W. W. i Conant, L. L. (2009). Where is the semantic system? A critical review and meta-analysis of 120 functional neuroimaging studies. *Cerebral Cortex*, 19, 2767-2796.
- Bonn, C. i Cantlon, J. F. (2012). The origins and structure of quantitative concepts. *Cognitive Neuropsychology*, 29, 149-173.
- Borghi, A. M., Glenberg, A. M. i Kaschak, M. P. (2004). Putting words in perspective. *Memory & Cognition*, 32, 863-873.
- Boroditsky, L. (2000). Metaphoric structuring: Understanding time through spatial metaphors. *Cognition*, 75, 1-28.
- Boroditsky, L. i Ramscar, M. (2002). The roles of body and mind in abstract thought. *Psychological Science*, 13, 185-188.
- Brannon, E.M. (2002). The development of ordinal numerical knowledge in infancy. *Cognition*, 83, 223-240.
- Brigner, W. L. (1988). Perceived duration as a function of pitch. *Perceptual & Motor Skills*, 67, 301-302.
- Brody, C. D., Hernandez, A., Zainos, A. i Romo, R. (2003). Timing and neural encoding of somatosensory parametric working memory in macaque prefrontal cortex. *Cerebral Cortex*, 13, 1196-1207.
- Buccino, G., Raggio, L., Melli, G., Binkofski, F., Gallese, V. i Rizzolatti, G. (2005). Listening to action-related sentences modulates the activity of the motor system: a combined TMS and behavioral study. *Cognitive Brain Research*, 24, 355-363.
- Buetti, D. i Walsh, V. (2009). The parietal cortex and the representation of time, space, number, and other magnitudes. *Philosophical Transactions of the Royal Society of London B*, 364, 1831-1840.
- Burgess, C. i Lund, K. (1997). Modeling parsing constraints with high-dimensional contextspace. *Language and Cognitive Processes*, 12, 177-210.

- Burr, D. C., Turi, M. i Anobile, G. (2010). Subitizing but not estimation of numerosity requires attentional resources. *Journal of Vision*, 6(10):20.
- Butterworth, B. (2010). Foundational numerical capacities and the origins of dyscalculia. *Trends in Cognitive Sciences*, 14, 534-541.
- Butterworth, B., Reeve, R., Reynolds, F. i Lloyd, D. (2008). Numerical thought with and without words: evidence from indigenous Australian children. *Proceedings of the National Academy of Sciences of the United States of America*, 105, 13179-13184.
- Calabria, M. i Rossetti, Y. (2005). Interference between number processing and line bisection: a methodology. *Neuropsychologia*, 43, 779-783.
- Camos, V. i Tillmann, B. (2008). Discontinuity in the enumeration of sequentially presented auditory and visual stimuli. *Cognition*, 107, 1135-1143.
- Campbell, J. I. D. (1991). Conditions of error priming in number-fact retrieval. *Memory & Cognition*, 19, 197-209.
- Campbell, J. I. D. (1994). Architectures for numerical cognition. *Cognition*, 53, 1-44.
- Campbell, J. I. D. (2008). Subtraction by addition. *Memory & Cognition*, 36, 1094-1110.
- Campbell, J. I. D. i Alberts, N. A. (2010). Inverse reference in adults' elementary arithmetic. *Canadian Journal of Experimental Psychology*, 64, 77-85.
- Campbell, J. I. D. i Clark, J. M. (1988). An encoding-complex view of cognitive number processing: Comment on McCloskey, Sokol, & Goodman (1986). *Journal of Experimental Psychology: General*, 117, 204-214.
- Campbell, J. I. D. i Clark, J. M. (1992). Numerical cognition: An encoding-complex perspective. U J. I. D. Campbell (Ur.), *The nature and origins of mathematical skills* (str. 457-491). Amsterdam: Elsevier.
- Campbell, J. I. D. i Fugelsang, J. (2001). Strategy choice for arithmetic verification: Effects of numerical surface form. *Cognition*, 80, B21-B30.
- Cappelletti, M., Butterworth, B. i Kopelman, M. (2001). Spared numerical abilities in a case of semantic dementia. *Neuropsychologia*, 39, 1224-1239.
- Caramazza, A., Anzellotti, S., Strnad, L. i Lingnau, A. (2014). Embodied cognition and mirror neurons: a critical assessment. *Annual Review of Neuroscience*, 37, 1-15.
- Carey, S. (2001). Evolutionary and ontogenetic foundations of arithmetic. *Mind and Language*, 16, 37-55.
- Carey, S. (2004). Bootstrapping and the origins of concepts. *Daedalus*, 133, 59-68.

- Carpenter, G. A. i Grossberg, S. (1993). Normal and amnesic learning, recognition, and memory by a neural model of cortico-hippocampal interactions. *Trends in Neurosciences*, 16, 131-137.
- Carpenter, G. A. i Grossberg, S. (2003). Adaptive resonance theory. U M.A. Arbib (Ur.), *The Handbook of brain theory and neural networks, Second Edition* (str. 87-90), Cambridge, MA: MIT Press.
- Caspers, S., Zilles, K., Laird, A. R. i Eickhoff, S. B. (2010). ALE meta-analysis of action observation and imitation in the human brain. *NeuroImage*, 50, 1148-1167.
- Cattaneo, L., Sandrini, M. i Schwarzbach, J. (2010). State-dependent TMS reveals a hierarchical representation of observed acts in the temporal, parietal, and premotor cortices. *Cerebral Cortex*, 20, 2252-2258.
- Chao, L. L. i Martin, A. (1999). Cortical regions associated with perceiving, naming and knowing about colors. *Journal of Cognitive Neuroscience*, 11, 25-35.
- Chatterjee, A. (2001). Language and space: some interactions. *Trends in Cognitive Sciences*, 5, 55-61.
- Chatterjee, A. (2010). Disembodying cognition. *Language & Cognition*, 2, 79-116.
- Chatterjee, A., Maher, L. M., Gonzalez Rothi, L. J., Heilman, i K. M. (1995). Asyntactic thematic role assignment: The use of a temporal-spatial strategy. *Brain and Language*, 49, 125-139.
- Chatterjee, A., Southwood, M. H., & Basilico, D. (1999). Verbs, events and spatial representations. *Neuropsychologia*, 37, 395-402.
- Chong, T. T., Cunnington, R., Williams, M. A., Kanwisher, N. i Mattingley, J. B. (2008). fMRI adaptation reveals mirror neurons in human inferior parietal cortex. *Current Biology*, 18, 1576-1580.
- Church, R. M. i Meck, W. H. (1984). The numerical attribute of stimuli. U H. L. Roitblatt, T. G. Bever i H. S. Terrace (Ur.), *Animal cognition* (str. 445-464). Hillsdale, NJ: Lawrence Erlbaum Assocs.
- Clark, A. (1999). An embodied cognitive science? *Trends in Cognitive Sciences*, 3, 345-351.
- Cipolotti, L., Butterworth, B. i Denes, G. (1991). A specific deficit for numbers in a case of dense acalculia. *Brain*, 114, 2619-2637.
- Cipolotti, L. i De Lacy Costello, A. (1995). Selective impairment for simple division. *Cortex*, 31, 433-449.
- Cohen, D. J. (2009). Integers do not automatically activate their quantity representation. *Psychonomic Bulletin & Review*, 16, 332-336.

- Cohen, L. i Dehaene, S. (2000). Calculating without reading: Unsuspected residual abilities in pure alexia. *Cognitive Neuropsychology*, 17, 563-583.
- Cohen Kadosh, R., Cohen Kadosh, K. i Henik, A. (2008). When brightness counts: The neuronal correlate of numerical-luminance interference. *Cerebral Cortex*, 18, 337-343.
- Cohen Kadosh, R. i Henik, A. (2006). A common representation for semantic and physical properties: A cognitive-anatomical approach. *Experimental Psychology*, 53, 87-94.
- Cohen Kadosh, R., Henik, A. i Walsh, V. (2007). Small is bright and big is dark in synaesthesia. *Current Biology*, 17, 834-835.
- Cohen Kadosh, R., Lammertyn, J. i Izard, V. (2008). Are numbers special? An overview of chronometric, neuroimaging, developmental and comparative studies of magnitude representation. *Progress in Neurobiology*, 84, 132-147.
- Cohen Kadosh, R. i Walsh, V. (2009). Numerical representation in the parietal lobes: Abstract or not abstract? *Behavioral and Brain Sciences*, 32, 313-373.
- Colby, C. L., & Golberg, M. E. (1999). Space and attention in parietal cortex. *Annual Review of Neuroscience*, 22, 319-349.
- Collins, A. M. i Quillian, M. R. (1969). Retrieval time from semantic memory. *Journal of Verbal Learning and Verbal Behavior*, 8, 240-247.
- Cooper, R. G. (1984). Early number development: Discovering number space with addition and subtraction. U C. Sophian (Ur.), *The origins of cognitive skills* (str. 157-192). Hillsdale, NJ: Lawrence Erlbaum.
- Coslett, H. B. (1999). Spatial influences on motor and language function. *Neuropsychologia*, 37, 695-706.
- Cordes, S. i Brannon, E. M. (2009). Crossing the divide: infants discriminate small from large numerosities. *Developmental Psychology*, 45, 1583-1594.
- Coubart, A., Izard, V., Spelke, E. S. , Marie, J. i Streri, A. (2014). Dissociation between small and large numerosities in newborn infants. *Developmental Science*, 17, 11-22.
- Crowder, R. G. i Neath, I. (1995). The influence of pitch on time perception in short melodies. *Music Perception*, 12, 379-386.
- Dantzig, T. (1967). *Number: The language of science*. New York: Free Press.
- Dehaene, S. (1992). Varieties of numerical abilities. *Cognition*, 44, 1-42.
- Dehaene, S. (2001). Précis of *The number sense*. *Mind and Language*, 16, 16-36.
- Dehaene, S. (2003). The neural basis of Weber-Fechner's law: Neuronal recordings reveal a logarithmic scale for number. *Trends in Cognitive Science*, 7, 145-147.

- Dehaene, S. (2009). Origins of mathematical intuitions: the case of arithmetic. *Annals of the New York Academy of Science*, 1156, 232-259.
- Dehaene, S. (2011). *The number sense. 2nd ed.* New York: Oxford University Press.
- Dehaene, S., Bossini, S. i Giraux, P. (1993). The mental representation of parity and numerical magnitude. *Journal of Experimental Psychology: General*, 122, 371-396.
- Dehaene, S. i Changeux, J. P. (1993). Development of elementary numerical abilities: a neural model. *Journal of Cognitive Neuroscience*, 5, 390-407.
- Dehaene, S. i Cohen, L. (1995). Toward an anatomical and functional model of number processing. *Mathematical Cognition*, 1, 83-120.
- Dehaene, S. i Cohen, L. (1997). Cerebral pathways for calculation: Double dissociation between rote verbal and quantitative knowledge of arithmetic. *Cortex*, 33, 219-250.
- Dehaene, S. i Cohen, L. (2007). Cultural recycling of cortical maps. *Neuron*, 56, 384-398.
- Dehaene, S., Dupoux, E. i Mehler, J. (1990). Is numerical comparison digital? Analogical and symbolic effects in two-digit number comparison. *Journal of Experimental Psychology: Human Perception & Performance*, 16, 626-641.
- Dehaene, S., Molko, N., Cohen, L. i Wilson, A. J. (2004). Arithmetic and the brain. *Current Opinion in Neurobiology*, 14, 218-224.
- Dehaene, S., Piazza, M., Pinel, P. i Cohen, L. (2003). Three parietal circuits for number processing. *Cognitive Neuropsychology*, 20, 487-506.
- Domijan, D. (2011). A computational model of fMRI activity in the intraparietal sulcus that supports visual working memory. *Cognitive, Affective, & Behavioral Neuroscience*, 11, 573-599.
- Domijan, D. i Šetić, M. (2009). Adaptive resonance as a neural basis of conceptual semantics. U N.A. Taatgen i H. van Rijn (Ur.), *Proceedings of the 31th Annual Conference of the Cognitive Science Society* (str. 2196-2201). Austin, TX: Cognitive Science Society.
- Domijan, D. i Šetić, M. (2016). Resonant dynamics of grounded cognition: Explanation of behavioral and neuroimaging data using the ART neural network. *Frontiers in Psychology*, 7:139, 1-13.
- Droit-Volet, S. (2010). Speeding up a master clock common to time, number, and length? *Behavioral Processes*, 85, 126-134.
- Duncan, G. J., Dowsett, C. J., Claessens, A., Magnuson, K., Huston, A. C., Klebanov, P., Pagani, L. S., Feinstein, L., Engel, M., Brooks-Gunn, J., Sexton, H., Duckworth, K. i

- Japel, C. (2007). School readiness and later achievement. *Developmental Psychology*, 43, 1428-1446.
- Eagleman, D. M. (2008). Human time perception and its illusions. *Current Opinion in Neurobiology*, 18, 131-136.
- Feigenson, L. i Carey, S. (2003). Tracking individuals via object-files: evidence from infants' manual search. *Developmental Science*, 6, 568-584.
- Feigenson, L. i Carey S. (2005). On the limits of infants' quantification of small object arrays. *Cognition*, 97, 295-313.
- Feigenson, L., Carey, S. i Hauser, M. (2002). The representations underlying infants' choice of more: object files versus analog magnitudes. *Psychological Science*, 13, 150-156.
- Feigenson, L., Dehaene S. i Spelke, E. (2004). Core systems of number. *Trends in Cognitive Sciences*, 8 (7), 307-314.
- Fias, W., Brysbaert, M., Geypens, F. i D'ydewalle, G. (1996). The importance of magnitude information in numerical processing: evidence from the SNARC effect. *Mathematical Cognition*, 2, 95-110.
- Fias, W. i Fischer, M. H. (2005). Spatial representation of numbers. U J. I. D. Campbell (Ur.), *Handbook of mathematical cognition* (str. 43-54). New York: Psychology Press.
- Fias, W., Lauwereyns, J. i Lammertyn, J. (2001). Irrelevant digits affect feature-based attention depending on the overlap of neural circuits. *Cognitive Brain Research*, 12, 415-423.
- Fischer, M. H. (2001). Number processing induces spatial performance biases. *Neurology*, 57, 822-826.
- Fischer, M. H., Castel, A. D., Dodd, M. D. i Pratt, J. (2003). Perceiving numbers causes spatial shifts of attention. *Nature Neuroscience*, 6, 555-556.
- Flombaum, J.I., Junge, J.A. i Hauser, M.D. (2005). Rhesus monkeys (*Macaca mulatta*) spontaneously compute addition operations over large numbers. *Cognition*, 97, 315-325.
- Fodor, J. A. (1975). *The language of thought*. Cambridge, MA: Harvard University Press.
- Fodor, J. A. (1983). *Modularity of mind: An essay on faculty psychology*. Cambridge, MA: MIT Press.
- Fodor, J. A. (1992). A theory of the child's theory of mind. *Cognition*, 44, 283-296.
- Fodor, J. A. i Pylyshyn, Z. W. (1988). Connectionism and cognitive architecture: A critical analysis. *Cognition*, 28, 3-71.
- Freedberg, D. i Gallese, V. (2007). Motion, emotion and empathy in esthetic experience. *Trends in Cognitive Sciences*, 11, 197-203.

- Fumarola, A., Prpic, V., Da Pos, O., Murgia, M., Umiltà, C. i Agostini, T. (2014). Automatic spatial association for luminance. *Attention, Perception & Psychophysics*, 76, 759-765.
- Gallese, V. (2003). The roots of empathy: the shared manifold hypothesis and the neural basis of intersubjectivity. *Psychopathology*, 36, 171-180.
- Gallese, V., i Goldman, A. (1998). Mirror neurons and the simulation theory of mind-reading. *Trends in Cognitive Sciences*, 2, 493-501.
- Gallese, V., Keysers, C. i Rizzolatti, G. (2004). A unifying view of the basis of social cognition. *Trends in Cognitive Sciences*, 8, 396-402.
- Gallese, V. i Lakoff, G. (2005). The brain's concepts: The role of the sensory-motor system in conceptual knowledge. *Cognitive Neuropsychology*, 22, 455-479.
- Gallistel, C. R. i Gelman, R. (1992). Preverbal and verbal counting and computation. *Cognition*, 44, 43-74.
- Gallistel, C. R. i Gelman, R. (2000) Non-verbal numerical cognition: from reals to integers. *Trends in Cognitive Sciences*, 4, 59-65.
- Gallistel, C. R. i Gelman, R. (2005). Mathematical cognition. U K. Holyoak i R. Morrison (Ur.) *The Cambridge handbook of thinking and reasoning* (str. 559-588). New York: Cambridge University Press.
- Ganor-Stern, D. i Tzelgov, J. (2008). Negative numbers are generated in the mind. *Experimental Psychology*, 55, 157-163.
- García-Orza, J., Perea, M., Abu Mallouh, R. i Carreiras, M. (2012). Physical similarity (and not quantity representation) drives perceptual comparison of numbers: Evidence from two Indian notations. *Psychonomic Bulletin and Review*, 19, 294-300.
- Gebuis, T. i van der Smagt, M. J. (2011). Incongruence in number-luminance congruency effects. *Attention, Perception & Psychophysics*, 37, 259-265.
- Gelman, R. i Butterworth, B. (2005). Language and number: How are they related? *Trends in Cognitive Sciences*, 9, 6-10.
- Gelman, R. i Gallistel, C. R. (1978). *The child's understanding of number*. Cambridge, MA: Harvard University Press.
- Gelman, R. i Gallistel, C. R. (2004). Language and the origin of numerical concepts. *Science*, 306, 441-443.
- Gerstmann, J. (1940). Syndrome of finger agnosia, disorientation for right and left, agraphia, and acalculia. *Archives of Neurology: Psychiatry*, 44, 398-408.
- Gevers, W. i Lammertyn, J. (2005). The hunt for SNARC. *Psychology Science*, 47 (1), 10-21.

- Gevers, W., Santens, S., Dhooge, E., Chen, Q., Van den Bossche, L., Fias, W. i Verguts, T. (2010). Verbal-spatial and visuo-spatial coding of number-space interactions. *Journal of Experimental Psychology: General*, 139, 180-190.
- Gibbs, R. W. (2006). *Embodiment and cognitive science*. New York: Cambridge University Press.
- Gibson, J. J. (1979). *The ecological approach to visual perception*. Boston, MA: Houghton Mifflin.
- Glenberg, A. M. (2010). Embodiment as a unifying perspective for psychology. *Wiley Interdisciplinary Reviews: Cognitive Science*, 1, 586-596.
- Glenberg, A. M. i Gallese, V. (2012). Action-based Language: A theory of language acquisition, comprehension, and production. *Cortex*, 48, 905-922.
- Glenberg, A. M., Gutierrez, T., Levin, J. R., Japuntich, S. i Kaschak, M. P. (2004). Activity and imagined activity can enhance young children's reading comprehension. *Journal of Educational Psychology*, 96, 424-436.
- Glenberg, A. M., Havas, D., Becker, R. i Rinck, M. (2005). Grounding language in bodily states: The case for emotion. U D. Pecher i R.A. Zwaan, *Grounding cognition* (str. 115-128). New York: Cambridge University Press.
- Glenberg, A. M. i Kaschak, M. P. (2002). Grounding language in action. *Psychonomic Bulletin & Review*, 9, 558-565.
- Glenberg, A. M. i Robertson, D. A. (1999). Indexical understanding of instructions. *Discourse Processes*, 28, 1-26.
- Glenberg, A. M. i Robertson, D. A. (2000). Symbol grounding and meaning: A comparison of high-dimensional and embodied theories of meaning. *Journal of Memory & Language*, 43, 379-401.
- Glenberg, A. M., Sato, M., Cattaneo, L., Riggio, L., Palumbo, D. i Buccino, G. (2008). Processing abstract language modulates motor system activity. *Quarterly Journal of Experimental Psychology*, 61, 905-919.
- Glenberg, A. M., Witt, J. K. i Metcalfe, J. (2013). From the revolution to embodiment: 25 years of cognitive psychology. *Perspectives on Psychological Science*, 8, 573-585.
- Goldin-Meadow, S. (2014). How gesture works to change our minds. *Trends in Neuroscience and Education*, 3, 4-6.
- Goldin-Meadow, S. i Beilock, S. L. (2010). Action's influence on thought: The case of gesture. *Perspectives on Psychological Science*, 5, 664-674.

- Goldin-Meadow, S., Cook, S. W. i Mitchell, Z. A. (2009). Gesturing gives children new ideas about math. *Psychological Science*, 20, 267-272.
- Gordon, P. (2004) Numerical cognition without words: evidence from Amazonia. *Science*, 306, 496-499.
- Goswami, U. (2008). *Cognitive development*. Hove, UK: Psychology Press.
- Gouvêa, F. Q. (2008). From numbers to number systems. U T. Gowers (Ur.), *The Princeton companion to mathematics* (str. 77-83). Princeton, NJ: Princeton University Press.
- Göbel, S. M., Walsh, V. i Rushworth, M. F. S. (2001). The mental number line and the human angular gyrus. *NeuroImage*, 14, 1278-1289.
- Göbel, S. M., Watson, S. E., Lervag, A. i Hulme, C. (2014). Children's arithmetic development : It is number knowledge, not the approximate number sense, that counts. *Psychological Science*, 25, 789-798.
- Grill-Spector, K., Henson, R. i Martin, A. (2006). Repetition and the brain: Neural models of stimulus-specific effects. *Trends in Cognitive Sciences*, 10, 14-23.
- Groen, G. J. i Parkman, J. M. (1972). A chronometric analysis of simple addition. *Psychological Review*, 79, 329-343.
- Grossberg, S. (1980). How does a brain build a cognitive code? *Psychological Review*, 87, 1-51.
- Grossberg, S. (1999). The link between brain learning, attention, and consciousness. *Consciousness and Cognition*, 8, 1-44.
- Grossberg, S. (2007). Consciousness CLEARs the mind. *Neural Networks*, 20, 1040-1053.
- Grossberg, S. (2012). Adaptive Resonance Theory: How a brain learns to consciously attend, learn, and recognize a changing world. *Neural Networks*, 37, 1-47.
- Grossberg, S. i Seidman, D. (2006). Neural dynamics of autistic behaviors: Cognitive, emotional, and timing substrates. *Psychological Review*, 113, 483-525.
- Harnad, S. (1990). The symbol grounding problem. *Physica D*, 42, 335-346.
- Hauser, M. D., Carey, S. i Hauser, L. B. (2000). Spontaneous number representation in semi-free-ranging rhesus monkeys. *Proceedings of the Royal Society of London B: Biological Sciences*, 267, 829-833.
- Hecht, S. A. (2002). Counting on working memory in simple arithmetic when counting is used for problem solving. *Memory & Cognition*, 30, 447-455.
- Henik, A. i Tzelgov, J. (1982). Is three greater than five: the relation between physical and semantic size in comparison tasks. *Memory & Cognition*, 10, 389-395.

- Hittmair-Delazer, M., Sailer, U. i Benke, T. (1995). Impaired arithmetic facts but intact conceptual knowledge: A single case study of dyscalculia. *Cortex*, 31, 139-147.
- Holloway, I. D., Price, G. R. i Ansari, D. (2010). Common and segregated neural pathways for the processing of symbolic and nonsymbolic numerical magnitude: An fMRI study. *NeuroImage*, 49, 1006-1017.
- Hsu, N. S., Kraemer, D. J. M., Oliver, R. T., Schlichting, M. L. i Thompson-Schill, S. L. (2011). Color, context, and cognitive style: Variations in color knowledge retrieval as a function of task and subject variables. *Journal of Cognitive Neuroscience*, 23, 2544-2557.
- Hubbard, E. M., Piazza, M., Pinel, P. i Dehaene, S. (2005). Interactions between number and space in parietal cortex. *Nature Reviews Neuroscience*, 6, 435-48.
- Huntley-Fenner, G. (2001). Children's understanding of number is similar to adults' and rats': Numerical estimation by 5- to 7-year-olds. *Cognition*, 78, B27-B40.
- Huntley-Fenner, G. i Cannon, E. (2000). Preschoolers' magnitude comparisons are mediated by a preverbal analog mechanism. *Psychological Science*, 11, 147-152.
- Hyde, D. C. (2011). Two systems of non-symbolic numerical cognition. *Frontiers in Human Neuroscience*, 5:150.
- Hyde, D. C., Khanum, S. i Spelke, E. S. (2014). Brief non-symbolic, approximate number practice enhances subsequent exact symbolic arithmetic in children. *Cognition*, 131, 92-107.
- Hyde, D. C. i Spelke, E. S. (2009). All numbers are not equal: An electrophysiological investigation of small and large number representations. *Journal of Cognitive Neuroscience*, 21, 1039-1053.
- Hyde, D. C. i Spelke, E. S. (2011). Neural signatures of number processing in human infants: Evidence for two core systems underlying numerical cognition. *Developmental Science*, 14, 360-371.
- Iacoboni, M. (2009). Imitation, empathy, and mirror neurons. *Annual Review of Psychology*, 60, 653-670.
- Iacoboni, M. i Dapretto, M. (2006). The mirror neuron system and the consequences of its dysfunction. *Nature Reviews Neuroscience*, 7, 942-951.
- Izard, V. i Dehaene, S. (2008). Calibrating the mental number line. *Cognition*, 106, 1221-1247.
- Jackson, P.L., Meltzoff, A.N. i Decety, J. (2005). How do we perceive the pain of others? A window into the neural processes involved in empathy. *NeuroImage*, 24, 771-779.

- Jacob, P. i Jeannerod, M. (2005). The motor theory of social cognition: a critique. *Trends in Cognitive Sciences*, 9, 21-25.
- James, T. W. i Gauthier, I. (2006). Repetition-induced changes in BOLD response reflect accumulation of neural activity. *Human Brain Mapping*, 27, 37-46.
- Jevons, W. S. (1871). The power of numerical discrimination. *Nature*, 3, 363-372.
- Jordan, K. E. i Brannon, E. M. (2006). The multisensory representation of number in infancy. *Proceedings of the National Academy of Sciences of the United States of America*, 103, 3486-3489.
- Kaschak, M. P., Madden, C. J., Theriault, D. J., Yaxley, R. H., Aveyard, M., Blanchard, A. A., & Zwaan, R. A. (2005). Perception of motion affects language processing. *Cognition*, 94, 79-89.
- Kaufman, E. L., Lord, M. W., Reese, T. i Volkman, J. (1949). The discrimination of visual number. *American Journal of Psychology*, 62, 496-525.
- Kemmerer, D., Rudrauf, D., Manzel, K. i Tranel, D. (2012). Behavioral patterns and lesion sites associated with impaired processing of lexical and conceptual knowledge of actions. *Cortex*, 48, 826-848.
- Keysers, C. i Gazzola, V. (2006). Towards a unifying neural theory of social cognition, *Progress in Brain Research*, 16, 1824-1829.
- Keysers, C. i Gazzola, V. (2007). Integrating simulation and theory of mind: from self to social cognition. *Trends in Cognitive Sciences*, 11, 194-196.
- Keysers, C. i Perrett, D.I. (2004). Demystifying social cognition: a Hebbian perspective. *Trends in Cognitive Sciences*, 8, 501-507.
- Keysers, C., Wicker, B., Gazzola, V., Anton, J.L., Fogassi, L. i Gallese, V. (2004) A touching sight: SII/PV activation during the observation and experience of touch. *Neuron*, 42, 335-346.
- Kiefer, M., i Barsalou, L. W. (2013). Grounding the human conceptual system in perception, action, and internal states. U W. Prinz, M. Beisert i A. Herwig (Ur.), *Action science: Foundations of an emerging discipline* (str. 381-407). Cambridge, MA: MIT Press.
- Kiefer, M., Sim, E.-J., Herrnberger, B., Grothe, J. i Hoenig, K. (2008). The sound of concepts: Four markers for a link between auditory and conceptual brain systems. *The Journal of Neuroscience*, 28, 12224-12230.
- Kintsch, W. (1988). The role of knowledge in discourse comprehension: A construction-integration model. *Psychological Review*, 95, 163-182.

- Knops, A., Thirion, B., Hubbard, E.M., Michel, V. i Dehaene, S. (2009). Recruitment of an area involved in eye movements during mental arithmetic. *Science*, 324, 1583-1585.
- Knops, A., Viarouge, A. i Dehaene, S (2009). Dynamic representations underlying symbolic and nonsymbolic calculation: Evidence from the operational momentum effect. *Attention, Perception & Psychophysics*, 71, 803-821.
- Kontra, C. E., Goldin-Meadow, S. i Beilock, S. L. (2012). Embodied learning across the lifespan. *Topics in Cognitive Science*, 4, 731-739.
- Kousta, S. T., Vigliocco, G., Vinson, D. P., Andrews, M. i Del Campo, E. (2011). The representation of abstract words: Why emotion matters. *Journal of Experimental Psychology: General*, 140, 14-34.
- Laird, J. E., Rosenbloom, P. S. i Newell, A. (1987). Soar: An architecture for general intelligence. *Artificial Intelligence*, 33, 1-64.
- Lakens, D. (2011). High skies and oceans deep: Polarity benefits or mental simulation? *Frontiers in Psychology*, 2:21.
- Lakens, D., Semin, G. R. i Foroni, F. (2012). But for the bad, there would not be good: Grounding valence in brightness through structural similarity. *Journal of Experimental Psychology: General*, 141, 584-594.
- Lakoff, G. i Johnson, M. (1980). *Metaphors we live by*. Chicago, IL: University of Chicago Press.
- Lakoff, G. i Johnson, M. (1990). *Philosophy in the flesh: The embodied mind and its challenge to western thought*. New York: Basic Books.
- Lakoff, G. i Nunez, R. (2000). *Where mathematics comes from: How the embodied mind brings mathematics into being*. New York: Basic Books.
- Landau, M. J., Meier, B. P. i Keefer, L. A. (2010). A metaphor-enriched social cognition. *Psychological Bulletin*, 136, 1045-1067.
- Landauer, T. i Dumais, S. (1997). A solutions to Plato's problem: The Latent Semantic Analysis theory of acquisition, induction and representation of knowledge. *Psychological Review*, 104, 211-240.
- Landy, D. H. i Goldstone, R. L. (2007). How abstract is symbolic thought? *Journal of Experimental Psychology: Learning, Memory, & Cognition*, 33, 720-733.
- Landy, D. H. i Goldstone, R. L. (2010). Proximity and precedence in arithmetic. *The Quarterly Journal of Experimental Psychology*, 63, 1953-1968.
- Le Corre, M. i Carey, S. (2007). One, two, three, four, nothing more: an investigation of the conceptual sources of the verbal counting principles. *Cognition*, 105, 395-438.

- Lee, S. W. S. i Schwarz, N. (2010a). Of dirty hands and dirty mouths: Embodiment of the moral purity metaphor is specific to the motor modality involved in moral transgression. *Psychological Science*, 21, 1423-1425.
- Lee, W. S. i Schwarz, N. (2010b). Washing away post-decisional dissonance. *Science*, 328, 709.
- Leon, M. I. i Shadlen, M. N. (2003). Representation of time by neurons in the posterior parietal cortex of the macaque. *Neuron*, 38, 317-327.
- Leslie, A. M., Gelman, R., Gallistel, C. R. (2007). Where integers come from. U P. Carruthers, S. Laurence i S. Stich (Ur.), *The Innate Mind, Vol. 3: Foundations and the Future* (str. 109-138). New York: Oxford University Press.
- Leslie, A. M., Gelman, R. i Gallistel, C. R. (2008). The generative basis of natural number concepts. *Trends in Cognitive Sciences*, 12, 213-218.
- Lipton, J. S. i Spelke, E. S. (2004). Discrimination of large and small numerosities by human infants. *Infancy*, 5, 271-290.
- Logan, G. D. (1990). Repetition priming and automaticity: Common underlying mechanisms? *Cognitive Psychology*, 22, 1-35.
- Louwerse, M. M. (2011). Symbol interdependency in symbolic and embodied cognition. *Topics in Cognitive Science*, 3, 273-302.
- Luck, S. J. i Vogel, E. K. (1997). The capacity of visual working memory for features and conjunctions. *Nature*, 390, 279-281.
- Maglio, S. J. i Trope, Y. (2012). Disembodiment: Abstract construal attenuates the influence of contextual bodily state in judgment. *Journal of Experimental Psychology: General*, 141, 211-216.
- Mahon, B. Z. i Caramazza, A. (2008). A critical look at the Embodied Cognition Hypothesis and a new proposal for grounding conceptual content. *Journal of Physiology - Paris*, 102, 59-70.
- Mandler, G. i Shebo, B. J. (1982). Subitizing: An analysis of its component processes. *Journal of Experimental Psychology: General*, 111, 1-22.
- Markman, A. B. i Brendl, C. M. (2005). Constraining theories of embodied cognition. *Psychological Science*, 16, 6-10.
- Markman, A. B. i Dietrich, E. (2000). Extending the classical view of representation. *Trends in Cognitive Sciences*, 4, 470-475.
- Marschak, A. (1972). *The roots of civilization*. New York: McGraw-Hill.

- Martin, A. (2001). Functional neuroimaging of semantic memory. U R. Cabeza i A. Kingstone (Ur.), *Handbook of functional neuroimaging of cognition* (str. 153-186). Cambridge, MA: MIT Press.
- Martin, A. (2007). The representation of object concepts in the brain. *Annual Review of Psychology*, 58, 25-45.
- Martin, A. (2009). Circuits in mind: The neural foundations for object concepts. U M. Gazzaniga (Ur.), *The cognitive neurosciences. 4. izdanje* (str. 1031-1045). Cambridge, MA: MIT Press.
- McCloskey, M. (1992). Cognitive mechanisms in numerical processing: Evidence from acquired dyscalculia. *Cognition*, 44, 107-157.
- McCloskey, M. i Macaruso, P. (1994). Architecture of cognitive numerical processing mechanisms: Contrasting perspectives on theory development and evaluation. *Cahiers de Psychologie Cognitive/Current Psychology of Cognition*, 13, 275-295.
- McCloskey, M. i Macaruso, P. (1995). Representing and using numerical information. *American Psychologist*, 50, 351-363.
- McCrink, K., Dehaene, S. i Dehaene-Lambertz, G. (2007). Moving along the number line: operational momentum in nonsymbolic arithmetic. *Perception & Psychophysics*, 69, 1324-1333.
- McNeil, N. M. i Uttal, D. H. (2009). Rethinking the use of concrete materials in learning: Perspectives from development and education. *Child Development Perspectives*, 3, 137-139.
- McNeil, N. M., Uttal, D. H., Jarvin, L. i Sternberg, R. J. (2009). Should you show me the money? Concrete objects both hurt and help performance on mathematics problems. *Learning and Instruction*, 19, 171-184.
- Mechner, F. (1958). Probability relations within response sequences under ratio reinforcement. *Journal of Experimental Analysis of Behavior*, 1, 109-122.
- Mechner, F. (1962). Effects of deprivation upon counting and timing in rats. *Journal of the Experimental Analysis of Behavior*, 5, 463-466.
- Meck, W. H. i Church, R. M. (1983). A mode control model of counting and timing processes. *Journal of Experimental Psychology: Animal Behavior Processes*, 9, 320-334.
- Meier, B. P. i Robinson, M. D. (2004). Why the sunny side is up: Associations between affect and vertical position. *Psychological Science*, 15, 243-247.

- Meier, B. P., Robinson, M. D., & Clore, G. L. (2004). Why good guys wear white: Automatic inferences about stimulus valence based on brightness. *Psychological Science*, 15, 82-87.
- Meier, B. P., Robinson, M. D., Crawford, L. E. i Ahlvers, W. J. (2007). When 'light' and 'dark' thoughts become light and dark responses: Affect biases brightness judgments. *Emotion*, 7, 366-376.
- Meier, B. P. i Robinson, M. D. (2005). The metaphorical representation of affect. *Metaphor and Symbol*, 20, 239-257.
- Meier, B. P. i Robinson, M. D. (2006). Does "feeling down" mean seeing down?: Depressive symptoms and vertical selective attention. *Journal of Research in Personality*, 40, 451-461.
- Meier, B. P., Schnall, S., Schwarz, N. i Bargh, J. A. (2012). Embodiment in social psychology. *Topics in Cognitive Science*, 4, 705-716.
- Meteyard, L., Cuadrado, S. R., Bahrami, B. i Vigliocco, G. (2012). Coming of age: A review of embodiment and the neuroscience of semantics. *Cortex*, 48, 788-804.
- Mix, K. S. (2010). Spatial tools for mathematical thought. U K. S. Mix, L. B. Smith i M. Gasser (Ur.), *Space and language* (str. 41–66). New York, NY: Oxford University Press.
- Moyer, R. S. i Landauer, T. K. (1967). Time required for judgments of numerical inequality. *Nature*, 215, 1519-1520.
- Moyer, R. S. i Landauer, T. K. (1973). Determinants of reaction time for digit inequality judgments. *Bulletin of the Psychonomic Society*, 1, 167-168.
- Negri, G. A. L., Rumiati, R. I., Zadini, A., Ukmair, M., Mahon, B. Z. i Caramazza, A. (2007). What is the role of motor simulation in action and object recognition? Evidence from apraxia. *Cognitive Neuropsychology*, 24, 795-816.
- Niedenthal, P. M., Barsalou, L. W., Winkielman, P., Krauth-Gruber, S., & Ric, F. (2005). Embodiment in attitudes, social perception, and emotion. *Personality and Social Psychology Review*, 9, 184-211.
- Nieder, A. (2005). Counting on neurons: The neurobiology of numerical competence. *Nature Reviews Neuroscience*, 6, 177-190.
- Nieder, A. i Dehaene, S. (2009). Representation of number in the brain. *Annual Review of Neuroscience*, 32, 185-208.
- Nieder, A., Freedman, D. J. i Miller, E. K. (2002). Representation of the quantity of visual items in the primate prefrontal cortex. *Science*, 297, 1708-1711.

- Nieder, A., i Merten, K. (2007). A labeled-line code for small and large numerosities in the monkey prefrontal cortex. *Journal of Neuroscience*, 27, 5986-5993.
- Nieder, A. i Miller, E. K. (2003). Coding of cognitive magnitude: compressed scaling of numerical information in the primate prefrontal cortex. *Neuron*, 37, 149-157.
- Nieder, A. i Miller E. K. (2004). A parieto-frontal network for visual numerical information in the monkey. *Proceedings of the National Academy of Sciences of the United States of America*, 101, 7457-7462.
- Ninokura, Y., Mushiake, H. i Tanji, J. (2003). Representation of the temporal order of visual objects in the primate lateral prefrontal cortex. *Journal of Neurophysiology*, 89, 2868-2873.
- Ninokura, Y., Mushiake, H. i Tanji, J. (2004). Integration of temporal order and object information in the monkey lateral prefrontal cortex. *Journal of Neurophysiology*, 91, 555-560.
- Novack, M. A., Congdon, E. L., Hemani-Lopez, N. i Goldin-Meadow, S. (2014). From action to abstraction: Using the hands to learn math. *Psychological Science*, 25, 903-910.
- Noël, M.-P., Fias, W. i Brysbaert, M. (1997). About the influence of the presentation format on arithmetical-fact retrieval processes. *Cognition*, 63, 335-374.
- Nuerk, H-C., Weger, U. i Willmes, K. (2001). Decade breaks in the mental number line? Putting the tens and units back in different bins. *Cognition*, 82, 25-33.
- Olson, I. R., Plotzker, A. i Ezzyat, Y. (2007). The Enigmatic temporal pole: a review of findings on social and emotional processing. *Brain*, 130, 1718-1731.
- Organisation for Economic Co-operation and Development (2010). *The high cost of low education performance: the long-run economic impact of improving PISA outcomes*. Paris: OECD.
- Pansky, A. i Algom, D. (1999). Stroop and Garner effects in comparative judgments of numerals: The role of attention. *Journal of Experimental Psychology: Human Perception and Performance*, 25, 39-58.
- Pansky, A. i Algom, D. (2002). Comparative judgment of numerosity and numerical magnitude: Attention preempts automaticity. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 26, 259-274.
- Papeo, L., Negri, G. A. L., Zadini, A. i Rumiati, R. I. (2010). Action performance and action-word understanding: Evidence of double dissociations in left-damaged patients. *Cognitive Neuropsychology*, 27, 428-461.

- Papeo, L., Pascual-Leone, P. i Caramazza, A. (2013). Disrupting the brain to validate hypotheses on the neurobiology of language. *Frontiers in Human Neuroscience*, 7:148, 1-8.
- Papeo L. i Rumiatì R. I. (2013). Lexical and gestural symbols in left-brain damaged patients. *Cortex*, 49, 1668-1678.
- Parkman, J. M. (1971). Temporal aspects of digit and letter inequality judgments. *Journal of Experimental Psychology*, 91, 191-205.
- Parsons, S. i Bynner, J. (2005). *Does numeracy matter more?* London: National Research and Development Centre for Adult Literacy and Numeracy.
- Patterson, K., Nestor, P. i Rogers, T. T. (2007). Where do you know what you know? The representation of semantic knowledge in the human brain. *Nature Reviews: Neuroscience*, 8, 976-987.
- Pecher, D., Zeelenberg, R. i Barsalou, L.W.(2003). Verifying properties from different modalities for concepts produces switching costs. *Psychological Science*, 14(2), 119-124.
- Pecher, D. i Zwaan, R.A. (2005). *Grounding cognition*. New York: Cambridge University Press.
- Perniss, P. I Vigliocco, G. (2014). The bridge of iconicity: from a world of experience to the experience of language. *Philosophical Transactions of the Royal Society London B Biological Sciences*, 369: 20130300.
- Pezzulo, G., Barsalou, L. W., Cangelosi, A., Fischer, M. A., McRae, K. i Spivey, M. (2011). The mechanics of embodiment: A dialogue on embodiment and computational modeling. *Frontiers in Cognition*, 2:5, 1-21.
- Pezzulo, G., Barsalou, L. W., Cangelosi, A., Fischer, M. A., McRae, K. i Spivey, M. (2013). Computational grounded cognition: A new alliance between grounded cognition and computational modeling. *Frontiers in Psychology*, 3:612, 1-11.
- Piazza, M. (2010). Neurocognitive start-up tools for symbolic number representations. *Trends in Cognitive Sciences*, 14, 542-551.
- Piazza, M., Fumarola, A., Chinello, A. Melcher, D. (2011). Subitizing reflects visuo-spatial object individuation capacity. *Cognition*, 121, 147-153.
- Piazza, M., Izard, V., Pinel, P., Le Bihan D. i Dehaene, S. (2004). Tuning curves for approximate numerosity in the human intraparietal sulcus. *Neuron*, 44, 547-555.

- Piazza, M., Mechelli, A., Butterworth, B. i Price, C.J. (2002). Are subitizing and counting implemented as separate or functionally overlapping processes? *Neuroimage*, 15, 435-446.
- Piazza, M., Pinel, P., Le Bihan, D. i Dehaene, S. (2007). A magnitude code common to numerosities and number symbols in human intraparietal cortex. *Neuron*, 53, 293-305.
- Pica, P., Lemer, C., Izard, V. i Dehaene, S. (2004). Exact and approximate arithmetic in an Amazonian indigene group. *Science*, 306, 499-503.
- Piffer, L., Agrillo, C. i Hyde, D. C. (2012). Small and large number discrimination in guppies. *Animal Cognition*, 15, 215-221.
- Pinel, P., Piazza, M., LeBihan, D. i Dehaene, S. (2004). Distributed and overlapping cerebral representations of number size and luminance during comparative judgments. *Neuron*, 41, 983-993.
- Pinker, S. (1997). *How the mind works*. New York: Norton.
- Plaisier, M. A., Bergmann Tiest, W. M. i Kappers, A. M. (2009). One, two, three, many: Subitizing in active touch. *Acta Psychologica*, 131, 163-170.
- Press, C., Weiskopf, N. i Kilner, J. M. (2012). Dissociable roles of human inferior frontal gyrus during action execution and observation. *NeuroImage*, 60, 1671-1677.
- Proctor, R. W. i Cho, Y. S. (2006). Polarity correspondence: A general principle for performance of speeded binary classification tasks. *Psychological Bulletin*, 132, 416-442.
- Pulvermüller, F. (1999). Words in the brain's language. *Behavioral and Brain Sciences*, 22, 253-336.
- Pulvermüller, F. (2001). Brain reflections of words and their meaning. *Trends in Cognitive Sciences*, 5, 517-524.
- Pulvermüller, F. (2005). Brain mechanisms linking language and action. *Nature Reviews Neuroscience*, 6, 576-582.
- Pulvermüller, F. (2013). How neurons make meaning: Brain mechanisms for embodied and abstract-symbolic semantics. *Trends in Cognitive Sciences*, 17, 458-470.
- Pulvermüller, F. i Fadiga, L. (2010). Active perception: Sensorimotor circuits as a cortical basis for language. *Nature Reviews Neuroscience*, 11, 351-360.
- Pulvermüller, F., Hauk, O., Nikulin, V. i Ilmoniemi, R. J. (2005). Functional interaction of language and action: a TMS study. *European Journal of Neuroscience*, 21, 793-797.
- Pylyshyn, Z. W. (2011). *Things and places: How the mind connects with the world*. Cambridge, MA: MIT Press.

- Ratcliff, R. (1993). Methods for dealing with reaction time outliers. *Psychological Bulletin*, 114, 510-532.
- Ren, P., Nicholls, M. E. R., Ma, Y. i Chen, L. (2011). Size matters: Nonnumerical magnitude affects the spatial coding of response. *PLoS ONE*, 6, e23553.
- Repp, B. H. (2007). Perceiving the numerosity of rapidly occurring auditory events in metrical and nonmetrical contexts. *Perception & Psychophysics*, 69, 529-543.
- Restle, F. (1970). Speed of adding and comparing numbers. *Journal of Experimental Psychology*, 95, 437-444.
- Richardson, D.C., Spivey, M.J., Barsalou, L.W. i McRae, K. (2003). Spatial representations activated in real time comprehension of verbs. *Cognitive Science*, 27, 767-780.
- Riordan, B. i Jones, M. N. (2011). Redundancy in perceptual and linguistic experience: Exploring semantic categories in feature-based and distributional models of semantic representation. *Topics in Cognitive Science*, 3, 303-345.
- Rizzolatti, G. i Craighero, L. (2004). The mirror-neuron system. *Annual Review of Neuroscience*, 27, 169-192.
- Rizzolatti, G. i Sinigaglia, C. (2010). The functional role of the parieto- frontal mirror circuit: Interpretations and misinterpretations. *Nature Reviews Neuroscience*, 11, 264-274.
- Rizzolatti, G. i Sinigaglia, C. (2013). Understanding action from the inside. U W. Prinz, M. Beisert i A. Herwig (Ur.), *Action science: Foundations of an emerging discipline* (str. 201-227). Cambridge, MA: MIT Press.
- Roediger, H. L. i McDermott, K. B. (1993). Implicit memory in normal human subjects. U F. Boller i J. Grafman (Ur.), *Handbook of neuropsychology*, Vol. 8 (str. 63-131). Amsterdam: Elsevier.
- Rogers , T. T., Lambon Ralph, M. A, Garrard, P., Bozeat, S., McClelland, J. L., Hodges, J. R. i Patterson, K. (2004). The structure and deterioration of semantic memory: A neuropsychological and computational investigation. *Psychological Review*, 111, 205-235.
- Roitman, J. D., Brannon, E. M. i Platt, M. L. (2007). Monotonic coding of numerosity in macaque lateral intraparietal cortex. *PLoS Biology*, 5, e208.
- Romo, R., Brody, C. D., Hernandez, A. i Lemus, L. (1999). Neuronal correlates of parametric working memory in the prefrontal cortex. *Nature*, 399, 470-473.
- Ross, L. A. i Olson, I. R. (2009). Social cognition and the anterior temporal lobes. *NeuroImage*, 49, 3452-3463.

- Rosser, M. N., Warrington, E. K. i Cipolotti, L. (1995). The isolation of calculation skills. *Journal of Neurology*, 242, 78-81.
- Rossion, B. i Pourtois, G. (2004). Revisiting Snodgrass and Vanderwart's object databank: the role of surface detail in basic level object recognition. *Perception*, 33, 217-236.
- Roy, D. (2005). Grounding words in perception and action: computational insights. *Trends in Cognitive Sciences*, 9, 389-396.
- Roy, D. i Reiter, E. (2005). Connecting language to the world. *Artificial Intelligence*, 167, 1-12.
- Rugani, R., Regolin, L., i Vallortigara, G. (2008). Discrimination of small numerosities in young chicks. *Journal of Experimental Psychology: Animal Behavior Processes*, 34, 388-399.
- Rugani, R., Regolin, L. i Vallortigara, G. (2010). Imprinted numbers: Newborn chicks' sensitivity to number vs. continuous extent of objects they have been reared with. *Developmental Science*, 13, 790-797.
- Rugg, M. D. i Thompson-Schill, S. L. (2013). Moving forward with fMRI data. *Perspectives on Psychological Science*, 8, 84-87.
- Rumbaugh, D. M., Savage-Rumbaugh, S. i Hegel, M. T. (1987). Summation in the chimpanzee (*Pan troglodytes*). *Journal of Experimental Psychology: Animal Behavior Processes*, 13, 107-115.
- Rusconi, E., Kwan, B., Giordano, B. L., Umiltà, C. i Butterworth, B. (2006). Spatial representation of pitch height: The SMARC effect. *Cognition*, 99, 113-129.
- Santens, S. i Gevers, W. (2008). The SNARC effect does not imply a mental number line. *Cognition*, 108, 263-270.
- Sarama, J. i Clements, D. (2009). Concrete computer manipulatives in mathematics education. *Child Development Perspectives*, 3, 145-150.
- Sarnecka, B. W. i Gelman, S. A. (2004). Six does not just mean a lot: Preschoolers see number words as specific. *Cognition*, 92, 329-352.
- Saxe, G. B. (1977). A developmental analysis of notational counting. *Child Development*, 48, 1512-1520.
- Saxe, R. (2005). Against simulation: the argument from error. *Trends in Cognitive Sciences*, 9, 174-179.
- Schie, van, H. T., Mars, R. B., Coles, M. G. H. i Bekkering, H. (2004). Modulation of activity in medial frontal and motor cortices during error observation. *Nature Neuroscience*, 7, 549-554.

- Schneider, W., Eschman, A. i Zuccolotto, A. (2002). *E-Prime user's guide*. Pittsburgh, PA: Psychology Software Tools.
- Searle, J. R. (1980). Minds, brains, and programs. *Behavioral & Brain Sciences*, 3, 417-457.
- Shaki, S. i Petrusic, W. M. (2005). On the mental representation of negative numbers: Context-dependent SNARC effects with comparative judgments. *Psychonomic Bulletin and Review*, 12, 931-937.
- Shaughnessy, J. J., Zechmeister, E. B. i Zechmeister, J. (2011). *Research methods in psychology*. 9th edition. New York: McGraw Hill.
- Sherman, G. D. i Clore, G. L. (2009). The color of sin: White and black are perceptual symbols of moral purity and pollution. *Psychological Science*, 20, 1019-1025.
- Shor, R. E. (1971). Symbol processing speed differences and symbol interference effects in a variety of concepts domain. *Journal of General Psychology*, 85, 187-205.
- Siegler, R. S. (1987). The perils of averaging data over strategies: An example from children's addition. *Journal of Experimental Psychology: General*, 116, 250-264.
- Siegler, R. S. (1988). Strategy choice procedures and the development of multiplication skill. *Journal of Experimental Psychology: General*, 117, 258-275.
- Simon, O., Cohen, L., Mangin, J. F., Bihan, D. L. i Dehaene, S. (2002). Topographical layout of hand, eye, calculation and language-related areas in the human parietal lobe. *Neuron*, 33, 475-487.
- Simmons, W. K., Ramjee, V., Beauchamp, M. S., McRae, K., Martin, A. i Barsalou, L. W. (2007). A common neural substrate for perceiving and knowing about color. *Neuropsychologia*, 45, 2802-2810.
- Simmons, W. K., Martin, A. i Barsalou, L. W. (2005). Pictures of appetizing foods activate gustatory cortices for taste and reward. *Cerebral Cortex*, 15, 1602-1608.
- Singer, T., Seymour, B., O'Doherty, J., Kaube, H., Dolan, R.J. i Frith, C.D. (2004) Empathy for pain involves the affective but not sensory components of pain. *Science*, 303, 1157-1162.
- Smith, L. B. i Sera, M. (1992). A developmental analysis of the polar structure of dimensions. *Cognitive Psychology*, 24, 99-142.
- Snodgrass, J. G. i Vanderwart, M. (1980). A standardized set of 260 pictures: norms for name agreement, image agreement, familiarity, and visual complexity. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 6, 174-215.
- Solarz, A. K. (1960). Latency of instrumental responses as a function of compatibility with the meaning of eliciting verbal signs. *Journal of Experimental Psychology*, 59, 239-245.

- Solomon, K. O. i Barsalou, L. W. (2001). Representing properties locally. *Cognitive Psychology*, 43, 129-169.
- Solomon, K. O. i Barsalou, L. W. (2004). Perceptual simulation in property verification. *Memory & Cognition*, 32(2), 244-259.
- Stanfield, R. A. i Zwaan, R.A. (2001). The effect of implied orientation derived from verbal context on picture recognition. *Psychological Science*, 12, 153-156.
- Strack, F., Martin, L. L. i Stepper, S. (1988). Inhibiting and facilitating conditions of the human smile: A nonobtrusive test of the facial feedback hypothesis. *Journal of Personality and Social Psychology*, 54, 768-777.
- Sulkowski, G.M. i Hauser, M.D. (2001). Can rhesus monkeys spontaneously subtract? *Cognition*, 79, 239-262
- Thompson-Schill, S. L. (2003). Neuroimaging studies of semantic memory: Inferring “how” from “where.” *Neuropsychologia*, 41, 280-292.
- Townsend, J.T. i Ashby, F. G. (1978). Methods of modeling capacity in simple processing systems. U J. Castellan & F. Restle (Ur.), *Cognitive theory*. Vol. 3. (str. 200-239). Hillsdale, N.J.: Erlbaum.
- Townsend, J. T. i Ashby, F. G. (1983). *Stochastic modeling of elementary psychological processes*. Cambridge, UK: Cambridge University Press.
- Trick, L. M. i Pylyshyn, Z. W. (1994). Why are small and large numbers enumerated differently? A limited-capacity preattentive stage in vision. *Psychological Review*, 101, 80-102.
- Tudusciuc, O. i Nieder, A. (2007). Neuronal population coding of continuous and discrete quantity in the primate posterior parietal cortex. *Proceedings of the National Academy of Sciences of the United States of America*, 104, 14513-14518.
- Umiltà, M. A., Kohler, E., Gallese, V., Fogassi, L., Fadiga, L., Keysers, C. i Rizzolatti, G. (2001). “I know what you are doing”: a neurophysiological study. *Neuron*, 32, 91-101.
- Uttal, D. H., Scudder, K. V. i DeLoache, J. S. (1997). Manipulatives as symbols: A new perspective on the use of concrete objects to teach mathematics. *Journal of Applied Developmental Psychology*, 18, 37-54.
- van Dantzig, S., Pecher, D., Zeelenberg, R., & Barsalou, L.W. (2008). Perceptual processing affects conceptual processing. *Cognitive Science*, 32, 579-590.
- van Dijck, Gevers, W. i Fias, W. (2009). Numbers are associated with different types of spatial information depending on the task. *Cognition*, 113, 248-253.

- van Harskamp, N. J. i Cipolotti, L. (2001). Selective impairments for addition, subtraction and multiplication: Implications for the organisation of arithmetical facts. *Cortex*, 37, 363-388.
- van Harskamp, N. J., Rudge, P. i Cipolotti, L. (2002). Are multiplication facts implemented by the left supramarginal and angular gyri? *Neuropsychologia*, 40, 1786-1793.
- Vetter, P., Butterworth, B. i Bahrami, B. (2011). A candidate for the attentional bottleneck: Set-size specific modulation of right TPJ during attentive enumeration. *Journal of Cognitive Neuroscience*, 23, 728-736.
- Vigliocco, G., Vinson, D. P., Lewis, W. i Garrett, M. F. (2004). Representing the meanings of object and action words: The featural and unitary semantic space hypothesis. *Cognitive Psychology*, 48, 422-488.
- Vuilleumier, P., Ortigue, S. i Brugger, P. (2004). The number space and neglect. *Cortex*, 40, 399-410.
- Walker, P., Bremner, J. G., Mason, U., Spring, J., Mattock, K., Slater, A., i sur. (2009). Preverbal infants' sensitivity to synaesthetic cross-modal correspondences. *Psychological Science*, 21, 21-25.
- Wallentin, M., Lund, T. E., Ostergaard, S., Ostergaard, L. i Roepstorff, A. (2005). Motion verb sentences activate left posterior middle temporal cortex despite static context. *NeuroReport*, 16, 649-652.
- Walsh, V. (2003). A theory of magnitude: Common cortical metrics of time, space and quantity. *Trends in Cognitive Sciences*, 7, 483-488.
- Walsh, V. i Pascual-Leone, A. (2003). *Transcranial magnetic stimulation: A neurochronometrics of mind*. Cambridge, MA: MIT Press.
- Wells, G. L. i Petty, R. E. (1980). The effects of overt head movements on persuasion: Compatibility and incompatibility of responses. *Basic and Applied Social Psychology*, 1, 219-230.
- Wicker, B., Keysers, C., Plailly, J., Royet, J.P., Gallese, V. i Rizzolatti, G. (2003). Both of us disgusted in my insula: the common neural basis of seeing and feeling disgust. *Neuron*, 40, 655-664.
- Wiese, H. (2003a). Iconic and non-iconic stages in number development: The role of language. *Trends in Cognitive Sciences*, 7, 385-390.
- Wiese, H. (2003b). *Numbers, language, and the human mind*. Cambridge, UK: Cambridge University Press.

- Willems, R. M., Hagoort, P. i Casasanto, D. (2010). Body-specific representations of action verbs: Neural evidence from right- and left-handers. *Psychological Science*, 21, 67-74.
- Willems, R. M., Toni, I., Hagoort, P. i Casasanto, D. (2010). Neural dissociations between action verb understanding and motor imagery. *Journal of Cognitive Neuroscience*, 22, 2387-2400.
- Williams, L. E. i Bargh, J. A. (2008). Experiencing physical warmth influences interpersonal warmth. *Science*, 322, 606-607.
- Wilson, M. (2002). Six views of embodied cognition. *Psychonomic Bulletin & Review*, 9, 625-636.
- Windes, J. D. (1968). Reaction time for numerical coding and naming numerals. *Journal of Experimental Psychology*, 78, 318-322.
- Winer, B. J. (1971). *Statistical principles in experimental design*. New York: McGraw-Hill.
- Wood, G., Nuerk, H.-C., Willmes, K. i Fischer, M. H. (2008). On the cognitive link between space and number: A meta-analysis of the SNARC effect. *Psychology Science Quarterly*, 50, 489-525.
- Wood, J. N. i Spelke, E. S. (2005). Infants' enumeration of actions: numerical discrimination and its signature limits. *Developmental Science*, 8, 173-181.
- Wu, L. L, i Barsalou, L. W. (2009). Perceptual simulation in conceptual combination: Evidence from property generation. *Acta Psychologica*, 132, 173-189.
- Wynn, K. (1990). Children's understanding of counting. *Cognition*, 36, 155-193.
- Wynn, K. (1992). Addition and subtraction by human infants. *Nature*, 358, 749-750.
- Xu, F. (2003). Numerosity discrimination in infants: Evidence for two system of representations. *Cognition*, 89, 15-25.
- Xu, F. i Spelke, E. S. (2000). Large number discrimination in 6-month-old infants. *Cognition*, 74, 1-11.
- Xu, F., Spelke, E. S. i Goddard, S. (2005). Number sense in human infants. *Developmental Science*, 8, 88-101.
- Xuan, B., Zhang, D., He, S. i Chen, X. (2007). Larger stimuli are judged to last longer. *Journal of Vision*, 7, 1-5.
- Zhong, C. B. i Leonardelli, G. J. (2008). Cold and lonely: Does social exclusion feel literally cold? *Psychological Science*, 19, 838-842.
- Zhong, C. B. i Liljenquist, K. (2006). Washing away your sins: Threatened morality and physical cleansing. *Science*, 313, 1451-1452.

- Zorzi, M., Priftis, K. i Umiltà, C. (2002). Brain damage: Neglect disrupts the mental number line. *Nature*, 417, 138-139.
- Zwaan, R. A. (2004). The immersed experiencer: Toward an embodied theory of language comprehension. U B.H. Ross, (Ur.), *The psychology of learning and motivation* (str. 35-62). New York: Academic Press.
- Zwaan, R. A., Madden, C. J., Yaxley, R. H. i Aveyard, M. E. (2004). Moving words: dynamic representations in language comprehension. *Cognitive Science*, 28, 611-619.
- Zwaan, R. A., Stanfield, R. A. i Yaxley, R. H. (2002). Do language comprehenders routinely represent the shapes of objects? *Psychological Science*, 13, 168-171.
- Zwaan, R.A. i Yaxley, R.H. (2003). Spatial iconicity affects semantic relatedness judgements. *Psychonomic Bulletin & Review*, 10, 954-958.

9. PRILOZI

9.1. Eksperiment 1

Aritmetički problemi korišteni u Eksperimentu 1 podijeljeni su u 4 liste, pri čemu je svaka lista imala 18 problema. Liste 1 i 3 kao i liste 2 i 4 sastojale su se od istih problema samo što je u jednoj listi problem imao točan odgovor, a u drugoj listi netočan. Na primjer u listi 1, $3 + 3 = 6$, dok je u listi 3, $3 + 3 = 4$. U svakoj listi bio je jednak broj točnih i netočnih problema i za zbrajanje i za oduzimanje. Unutar lista, problemi su prezentirani po slučaju, ali su liste prikazane fiksnim redoslijedom. Na taj način, osigurano je da se isti problem neće pojaviti s razmakom manjim od 18 pokušaja. Identične liste i problemi korišteni su i u Eksperimentu 2.

Lista 1:	Lista 2:	Lista 3:	Lista 4:
$3 + 3 = 6$	$2 - 2 = 0$	$3 + 3 = 4$	$2 - 2 = 3$
$4 - 4 = 1$	$5 + 5 = 13$	$4 - 4 = 0$	$5 + 5 = 10$
$6 - 6 = 0$	$7 + 7 = 14$	$6 - 6 = 3$	$7 + 7 = 11$
$9 + 9 = 16$	$8 - 8 = 3$	$9 + 9 = 18$	$8 - 8 = 0$
$2 + 7 = 9$	$4 - 2 = 2$	$7 + 2 = 11$	$4 - 2 = 0$
$5 - 3 = 4$	$2 + 5 = 6$	$5 - 3 = 2$	$5 + 2 = 7$
$9 - 4 = 5$	$9 + 2 = 11$	$9 - 4 = 6$	$2 + 9 = 10$
$6 + 8 = 17$	$6 - 3 = 1$	$8 + 6 = 14$	$6 - 3 = 3$
$9 + 7 = 16$	$7 - 3 = 4$	$7 + 9 = 13$	$7 - 3 = 6$
$8 - 3 = 3$	$9 + 3 = 13$	$8 - 3 = 5$	$3 + 9 = 12$
$7 - 5 = 2$	$4 + 5 = 9$	$7 - 5 = 3$	$5 + 4 = 6$
$6 + 2 = 7$	$6 - 4 = 0$	$2 + 6 = 8$	$6 - 4 = 2$
$5 + 9 = 14$	$8 - 4 = 4$	$9 + 5 = 11$	$8 - 4 = 3$
$8 - 2 = 3$	$8 + 5 = 10$	$8 - 2 = 6$	$5 + 8 = 13$
$4 - 3 = 1$	$6 + 7 = 13$	$4 - 3 = 0$	$7 + 6 = 14$
$5 + 6 = 8$	$9 - 6 = 5$	$6 + 5 = 11$	$9 - 6 = 3$
$2 + 3 = 5$	$8 - 7 = 1$	$3 + 2 = 7$	$8 - 7 = 3$
$7 - 4 = 4$	$9 + 8 = 18$	$7 - 4 = 3$	$8 + 9 = 17$

9.2. Eksperiment 4

Podražaji korišteni u Eksperimentu 4 u kojem su prezentirani samo zadaci zbrajanja. Liste su kreirane na isti način kao i u Eksperimentu 1.

Lista 1:	Lista 2:	Lista 3:	Lista 4:
$3 + 3 = 6$	$2 + 2 = 4$	$3 + 3 = 4$	$2 + 2 = 7$
$4 + 4 = 9$	$5 + 5 = 13$	$4 + 4 = 8$	$5 + 5 = 10$
$6 + 6 = 12$	$7 + 7 = 14$	$6 + 6 = 15$	$7 + 7 = 18$
$9 + 9 = 16$	$8 + 8 = 12$	$9 + 9 = 18$	$8 + 8 = 16$
$2 + 7 = 9$	$4 + 2 = 6$	$7 + 2 = 11$	$2 + 4 = 5$
$3 + 5 = 10$	$2 + 5 = 6$	$5 + 3 = 8$	$5 + 2 = 7$
$4 + 9 = 13$	$9 + 2 = 11$	$9 + 4 = 14$	$2 + 9 = 10$
$6 + 8 = 17$	$6 + 3 = 7$	$8 + 6 = 14$	$3 + 6 = 9$
$9 + 7 = 16$	$3 + 7 = 10$	$7 + 9 = 13$	$7 + 3 = 12$
$8 + 3 = 9$	$9 + 3 = 13$	$3 + 8 = 11$	$3 + 9 = 12$
$7 + 5 = 12$	$4 + 5 = 9$	$5 + 7 = 16$	$5 + 4 = 6$
$6 + 2 = 7$	$6 + 4 = 8$	$2 + 6 = 8$	$4 + 6 = 10$
$5 + 9 = 14$	$4 + 8 = 12$	$9 + 5 = 11$	$8 + 4 = 11$
$2 + 8 = 14$	$8 + 5 = 10$	$8 + 2 = 10$	$5 + 8 = 13$
$3 + 4 = 7$	$6 + 7 = 13$	$4 + 3 = 6$	$7 + 6 = 14$
$5 + 6 = 8$	$9 + 6 = 17$	$6 + 5 = 11$	$6 + 9 = 15$
$2 + 3 = 5$	$7 + 8 = 15$	$3 + 2 = 8$	$8 + 7 = 17$
$4 + 7 = 12$	$9 + 8 = 15$	$7 + 4 = 11$	$8 + 9 = 17$

9.3. Eksperiment 5

Podražaji korišteni u Eksperimentu 5 u kojem su prezentirani samo zadaci oduzimanja. Liste su kreirane na isti način kao i u Eksperimentu 1.

Lista 1:	Lista 2:	Lista 3:	Lista 4:
$3 - 3 = 0$	$2 - 2 = 0$	$3 - 3 = -2$	$2 - 2 = 3$
$4 - 4 = 1$	$5 - 5 = 3$	$4 - 4 = 0$	$5 - 5 = 0$
$6 - 6 = 0$	$7 - 7 = 0$	$6 - 6 = 3$	$7 - 7 = 4$
$9 - 9 = -2$	$8 - 8 = -4$	$9 - 9 = 0$	$8 - 8 = 0$
$2 - 7 = -5$	$4 - 2 = 2$	$7 - 2 = 7$	$2 - 4 = -1$
$3 - 5 = 0$	$2 - 5 = -4$	$5 - 3 = 2$	$5 - 2 = 3$
$4 - 9 = -5$	$9 - 2 = 7$	$9 - 4 = 6$	$2 - 9 = -8$
$6 - 8 = 1$	$6 - 3 = 1$	$8 - 6 = 2$	$3 - 6 = -3$
$9 - 7 = 2$	$3 - 7 = -4$	$7 - 9 = -5$	$7 - 3 = 6$
$8 - 3 = 3$	$9 - 3 = 7$	$3 - 8 = -5$	$3 - 9 = -6$
$7 - 5 = 2$	$4 - 5 = -1$	$5 - 7 = 2$	$5 - 4 = -2$
$6 - 2 = 3$	$6 - 4 = 0$	$2 - 6 = -4$	$4 - 6 = -2$
$5 - 9 = -4$	$4 - 8 = -4$	$9 - 5 = 1$	$8 - 4 = 3$
$2 - 8 = -2$	$8 - 5 = 0$	$8 - 2 = 6$	$5 - 8 = -3$
$3 - 4 = -1$	$6 - 7 = -1$	$4 - 3 = 0$	$7 - 6 = 2$
$5 - 6 = -4$	$9 - 6 = 5$	$6 - 5 = 1$	$6 - 9 = -3$
$2 - 3 = -1$	$7 - 8 = -1$	$3 - 2 = 4$	$8 - 7 = 3$
$4 - 7 = -2$	$9 - 8 = -1$	$7 - 4 = 3$	$8 - 9 = -1$

9.4. Eksperiment 6

Kao u Eksperimentu 1, i u Eksperimentu 6 kreirane su 4 liste kako bi se izbjeglo ponavljanje istog problema unutar 18 pokušaja. U svim listama bio je jednak broj zadataka množenja i dijeljenja od kojih je polovica bila s točnim odgovorom, a druga polovica s netočnim.

Lista 1:	Lista 2:	Lista 3:	Lista 4:
$3 * 3 = 9$	$2 * 2 = 4$	$3 / 3 = 1$	$2 / 2 = 1$
$4 / 4 = 2$	$5 / 5 = 4$	$4 * 4 = 18$	$5 * 5 = 27$
$6 / 6 = 1$	$7 / 7 = 1$	$6 * 6 = 36$	$7 * 7 = 49$
$9 * 9 = 79$	$8 * 8 = 60$	$9 / 9 = 3$	$8 / 8 = 2$
$7 * 2 = 14$	$4 * 2 = 8$	$14 / 2 = 7$	$4 / 2 = 2$
$15 / 3 = 7$	$10 / 5 = 1$	$5 * 3 = 18$	$2 * 5 = 8$
$36 / 9 = 4$	$18 / 2 = 9$	$4 * 9 = 36$	$2 * 9 = 18$
$6 * 8 = 45$	$6 * 3 = 16$	$48 / 8 = 2$	$18 / 3 = 9$
$9 * 7 = 63$	$3 * 7 = 21$	$63 / 7 = 9$	$21 / 7 = 3$
$24 / 3 = 6$	$9 / 3 = 4$	$8 * 3 = 21$	$9 * 3 = 23$
$35 / 5 = 7$	$20 / 5 = 4$	$7 * 5 = 35$	$5 * 4 = 20$
$6 * 2 = 8$	$6 * 4 = 22$	$12 / 2 = 3$	$24 / 4 = 3$
$5 * 9 = 45$	$4 * 8 = 32$	$45 / 9 = 5$	$32 / 8 = 4$
$16 / 8 = 6$	$40 / 8 = 2$	$8 * 2 = 20$	$5 * 8 = 36$
$12 / 4 = 3$	$42 / 7 = 6$	$3 * 4 = 12$	$6 * 7 = 42$
$5 * 6 = 27$	$9 * 6 = 58$	$30 / 5 = 5$	$54 / 6 = 8$
$2 * 3 = 6$	$8 * 7 = 56$	$6 / 3 = 2$	$56 / 8 = 7$
$28 / 7 = 5$	$72 / 9 = 4$	$7 * 4 = 29$	$8 * 9 = 76$

9.5. Eksperiment 7

Jednostavne fraze korištene u Eksperimentu 7 kako bi se stvorilo očekivanje o broju objekata koji će nakon fraze biti prikazani:

jedna mačka

dvije stolice

tri češlja

četiri mrkve

jedno pismo

dva jelena

tri krune

četiri psa

jedna ograda

dva cvijeta

tri bubnja

četiri ribe

jedna knjiga

dvije deve

tri leptira

četiri metle

jedna zebra

dvije čaše

tri prozora

četiri kotača

jedna violina

dvije vaze

tri kornjače

četiri trube

jedna rajčica

dva semafora

tri kravate

četiri tigra

jedan stol
dva telefona
tri jagode
četiri labuda
jedna žlica
dvije čarape
tri puža
četiri sanjke
jedna cipela
dvije ovce
tri pile
četiri škare
jedno ravnalo
dva pijetla
tri krumpira
četiri zeca
jedna kliješta
dva vrča
tri ananasa
četiri svinje
jedna paprika
dva pingvina
tri olovke
četiri kruške
jedan kist
dvije naranče
tri čavla
četiri gljive
jedan lav
dvije žarulje
tri lokota
četiri majmuna
jedna žaba

dva čekića
tri konja
četiri šešira

9.6. Eksperiment 8

Rečenice korištene u Eksperimentu 8 pomoću kojih je stvoreno očekivanje o broju objekata koji će nakon rečenice biti prikazani:

*Na drvo se popela jedna mačka
U sobi su bile dvije stolice
U frizerskom salonu su bila tri češlja
Zvonimir je kupio četiri mrkve
Prijatelj je napisao jedno pismo
Šumom su lutala dva jelena
U muzeju smo vidjeli tri krune
Ulicom su lutala četiri psa
Vrt je ograđen jednom ogradom
Mirta je ubrala i donijela dva cvijeta
Orkestar ima tri bubnja
Ribar je ulovio četiri ribe
Za ispit smo morali pročitati jednu knjigu
Pustinjom su hodale dvije deve
Oko cvijeća su oblijetala tri leptira
U spremištu su bile četiri metle
Savanom je lutala jedna zebra
Na šanku su bile dvije čaše
Stan je imao tri prozora
Ispred kuće su bila četiri kotača
U prtljazi je bila jedna violina
U hodniku se nalaze dvije vaze
Dvorištem su hodale tri kornjače
Marin posjeduje četiri trube
Na tanjuru je bila jedna rajčica
Na raskršću su bila dva semafora
Bojan je kupio tri kravate
U zoološkom vrtu smo vidjeli četiri tigra*

*U sredini sobe je bio jedan stol
Na polici su bila dva telefona
Ivan je uzeo tri jagode iz zdjele
Četiri labuda su plivala jezerom
Uz tanjur je bila jedna žlica
Josip je stavio dvije čarape na krevet
Na drvetu su puzala tri puža
Djeca su se spuštala na četiri sanjke
Đurđa je isprobala jednu cipelu
Dvije ovce su pasle travu na livadi
Šumari su donijeli tri pile
U ladici je bilo četvero škara
Nastavnik je donio u učionicu jedno ravnalo
U dvorištu su kukurikala dva pijetla
Gospođa je izvukla tri krumpira iz vrećice
Četiri zeca su se igrala u dvorištu
Radnik je donio jedna kliješta
Prijateljica je donijela dva vrča
U dućanu smo kupili tri ananasa
Četiri svinje su lutale poljem
Na tanjuru je ostala jedna paprika
Na fotografiji su bila dva pingvina
Učenik je stavio tri olovke na stol
U zdjeli su bile četiri kruške
Slikar je uzeo jedan kist
Ubrali smo dvije naranče
Goran je kupio tri čavla
Kolega je ubrao četiri gljive
U kavezu je bio jedan lav
Kupili smo dvije žarulje
Vrata su bila zaključana s tri lokota
Na grani su sjedila četiri majmuna
U močvari je kreketala jedna žaba*

*Majstor je donio dva čekića
Tri konja su kaskala na livadi
U izlogu dućana su bila četiri šešira*

10. ŽIVOTOPIS

Mia Šetić rođena je 28. srpnja 1982. godine u Zagrebu. Diplomirala je psihologiju 2006. godine na Filozofskom fakultetu u Rijeci, nakon čega je upisala doktorski studij psihologije na Filozofskom fakultetu u Zagrebu. Radila je kao analitičar u području istraživanja tržišta u agenciji Prizma istraživanja te agenciji Valicon. Od 2007. do 2013. godine bila je znanstveni novak na Odsjeku za psihologiju Filozofskog fakulteta u Rijeci te je kao asistent sudjelovala u izvođenju nastave na kolegijima *Osjeti i percepcija*, *Praktikumi iz eksperimentalne psihologije 1 i 2*, *Kognitivna neuroznanost*, *Kognitivno i neuralno modeliranje* i *Mozak i spoznaja*. Osim nastavnog rada na Odsjeku za psihologiju radila je kao istraživač na 3 znanstveno-istraživačka projekta: *Modeliranje kognitivnih i neuronskih sustava*; *Neuronsko modeliranje i bihevioralno testiranje vidne percepcije i kognicije*; i *Understanding the role of dendrites in cortical information processing*.

Dobitnica je Nagrade ZNANOST za objavljeni znanstveni rad u području društvenih i humanističkih znanosti koju dodjeljuje Hrvatska zaklada za znanost i psihologijske nagrade Zlatna značka Ramira Bujasa za osobito vrijedan diplomski rad u 2007. godini.

Trenutno je zaposlena kao viši predavač na Odjelu za psihologiju Hrvatskog katoličkog sveučilišta gdje predaje *Eksperimentalnu metodologiju*, *Učenje* i *Kognitivnu psihologiju* te radi kao suradnik/istraživač na projektima *Metacognition in Category Learning, Thinking and Comprehension* i *Kognitivni i neurodinamički aspekti percepcije, učenja i mišljenja* čiji je voditelj prof. dr. sc. Dražen Domijan s Filozofskog fakulteta u Rijeci.

Članica je međunarodnih društava za psihologijsku znanost Association for Psychological Science (APS) i Cognitive Science Society. Do sada je objavila 16 znanstvenih radova i sudjelovala na 30-tak međunarodnih i domaćih znanstvenih skupova.

11. POPIS OBJAVLJENIH RADOVA

Radovi u časopisima:

- Domijan, D. i Šetić, M. (2016). Resonant dynamics of grounded cognition: Explanation of behavioral and neuroimaging data using the ART neural network. *Frontiers in Psychology*, 7:139, 1-13.
- Tkalčić, M., Domijan, D., Pletikosić, S., Šetić, M. i Hauser, G. (2014). Attentional biases in irritable bowel syndrome patients. *Clinics and Research in Hepatology and Gastroenterology*, 38, 621-628.
- Domijan, D. i Šetić, M. (2010). Perception as a context for conceptual processing and language understanding. *Review of Psychology*, 17, 47-51.
- Supanc, V., Vargek-Solter, V., Bašić-Kes, V., Breitenfeld, T., Ramić, S., Zavoreo, I., Jergović, K., Šetić, M., Biloglav, Z. i Demarin, V. (2009). The evaluation of the stroke unit in Croatia at the University Hospital Sestre milosrdnice, Zagreb: 1995-2006 experience. *Collegium antropologicum*, 33, 1233-1238.
- Domijan, D., i Šetić, M. (2008). A feedback model of figure-ground assignment. *Journal of Vision*, 8(7):10, 1-27, <http://journalofvision.org/8/7/10/>.
- Pulanić, D., Polašek, O., Petrovečki, M. i suradnici (2008). Effects of human isolation and inbreeding on human quantitative traits: An example of biochemical markers of hemostasis and inflammation. *Human Biology*, 80, 513-533.
- Šetić, M., i Domijan, D. (2008). Modeling the top-down influences on the lateral interactions in the visual cortex. *Brain Research*, 1225, 86-101.
- Domijan, D., Šetić, M. i Švegar, D. (2007). A model of the illusory contour formation based on dendritic computation. *Neurocomputing*, 70, 1977-182.
- Šetić, M., Švegar, D. i Domijan, D. (2007). Modelling the statistical processing of visual information. *Neurocomputing*, 70, 1808-1812 .
- Šetić, M. i Domijan, D. (2007). The influence of vertical spatial orientation on property verification. *Language and Cognitive Processes*, 22, 297-312.

Radovi u zbornicima:

- Domijan, D. i Šetić, M. (2009). Adaptive resonance as a neural basis of conceptual semantics. U N.A. Taatgen i H. van Rijn (Ur.), *Proceedings of the 31th Annual Conference of*

- the Cognitive Science Society* (str. 2196-2201). Austin, TX: Cognitive Science Society.
- Rebić, V., Šetić, M. i Domijan, D. (2009). Brightness estimation in a neural network model with presynaptic inhibition. U M.A. Elliott, S. Antonijević, S. Berthaud, P. Mulcahy, C. Martyn, B. Bargery i H. Schmidt (Ur.), *Fechner Day 2009. Proceedings of the 25th Annual Meeting of the International Society for Psychophysics* (str. 359-362). Galway, Ireland: International Society for Psychophysics.
- Šetić, M. i Domijan, D. (2008). A computational model of saliency map read-out during visual search. U V. Kurkova, R. Neruda i J. Koutnik (Ur.), *Artificial Neural Networks – ICANN 2008*, (str. 433-442). Berlin: Springer.
- Domijan, D. i Šetić, M. (2007). Computing the maximum using presynaptic inhibition with glutamate receptors. U F. Mele, G. Ramella, S. Santillo i F. Ventriglia (Ur.), *Advances in brain, vision, and artificial intelligence*, (str. 418-427). Berlin: Springer.
- Šetić, M. i Domijan, D. (2007). A neural model for attentional modulation of lateral interactions in visual cortex. U F. Mele, G. Ramella, S. Santillo i F. Ventriglia (Ur.), *Advances in brain, vision, and artificial intelligence*, (str. 42-51). Berlin: Springer.
- Šetić, M. i Domijan D. (2007). A model for computing the average size and speed of visual objects. U V. Ćubela Adorić (Ur.) *15th Psychology Days in Zadar. Book of selected proceedings*, (str. 359-369). Zadar: Sveučilište u Zadru.